



Universidade Federal do Paraná
Programa de Pós-Graduação em
Engenharia de Manufatura



LUIZ CARLOS MACIEL DA SILVA
RASMUSSEN LUIS HALLES CONCEIÇÃO
KATIUSCA ANDREINA CALDERON GUEVARA

SISTEMA 4.0 PARA DIAGNÓSTICO DE DOENÇAS PULMONARES

CURITIBA
2020

LUIZ CARLOS MACIEL DA SILVA
RASMUSSEN LUIS HALLES CONCEIÇÃO
KATIUSCA ANDREINA CALDERON GUEVARA

SISTEMA 4.0 PARA DIAGNÓSTICO DE DOENÇAS PULMONARES

Trabalho apresentado como resultado parcial à obtenção do grau de Especialista em Engenharia Industrial 4.0. Curso de Pós Graduação em Engenharia Industrial 4.0, Setor de Tecnologia, Universidade Federal do Paraná.

Orientador: Prof. Dr. Pablo Deivid Valle

**CURITIBA
2020**

RESUMO

Praticamente todas as atividades humanas da atualidade possuem algum nível de relação com as tecnologias baseadas em Inteligência Artificial e no campo da medicina e saúde isto não é diferente.

Este relato técnico tem por objetivo apresentar um sistema para diagnóstico de doenças pulmonares a partir da avaliação computacional de imagens obtidas por meio de radiografias pulmonares. Contempla um breve resumo sobre três sistemas capazes de auxiliar neste diagnóstico (Sistema Especialista, Machine Learning e Deep Learning) e, por meio de uma matriz de decisão, escolhe o sistema que melhor se adapta e apresenta então detalhes sobre como o diagnóstico é realizado valendo-se do sistema escolhido.

Palavras-chave: Diagnóstico, Doenças Pulmonares, Deep Learning, Machine Learning, Sistema Especialista.

LISTA DE ILUSTRAÇÕES

FIGURA 1 – Teste de imagens de raio-x	11
---	----

LISTA DE TABELAS

TABELA 1 – Algumas situações apropriadas e inapropriadas para o uso de Sistema Especialistas:.....	7
TABELA 2 – Critérios e pesos para a matriz de decisão:.....	8
TABELA 3 – Matriz de Decisão:	9

CONTEÚDO

1. INTRODUÇÃO	5
2. A INDÚSTRIA 4.0 E O SISTEMA DE DIAGNÓSTICO DE DOENÇAS PULMONARES	6
2.1. A INDUSTRIA 4.0	6
2.2. COMO A INDUSTRIA 4.0 PODE AJUDAR NO DIAGNOSTICO DE DOENCAS PULMONARES 6	
2.3. SISTEMAS EXISTENTES.....	6
2.3.1. SISTEMAS ESPECIALISTAS.....	6
2.3.2. MACHINE LEARNING.....	7
2.3.3. DEEP LEARNING	8
3. RESULTADOS E DISCUSSÃO	10
3.1. CONFIGURAÇÃO DO DEEP LEARNING.....	10
4. CONSIDERAÇÕES FINAIS	12
REFERÊNCIAS BIBLIOGRÁFICAS.....	12

1. INTRODUÇÃO

A tecnologia tem evoluído muito nos últimos anos com esforços representativos em simular processos de inteligência humana por meio da interação com sistemas de computador. Dentro destes processos considera-se uma grande quantidade de informações e regras que ajudam a processá-los para realizar as ações solicitadas, fundamentando-se no uso de regras com objetivos de que o processo de decisão permita chegar a conclusões aproximadas ou a correções que sejam feitas através deste aprendizado de máquinas.

Em um contexto próprio da aplicação da inteligência artificial na área da saúde ainda há muito a desenvolver mas é essencial reconhecer a importância do desenvolvimento de algoritmos, aplicação de redes neurais artificiais, colheita de grandes massas de dados (Big Data) e a programação Paralela em GPUs (Unidade de Processamento Gráfico) para criar modelos com altos níveis de precisão.

Especificamente na área médica da leitura de imagens por radiografia, a compreensão pode ser extremamente complexa e tornar-se um desafio mesmo para especialistas experientes.

Por tanto, nosso trabalho tem aplicabilidade no auxílio ao médico especialista na leitura de imagens de radiografias para doenças pulmonares, com a finalidade de dar suporte à decisão do especialista.

Será apresentado um sistema para diagnóstico de doenças pulmonares a partir da avaliação computacional de imagens obtidas por meio de radiografias pulmonares.

A apresentação deste sistema segue os seguintes tópicos:

- Breve resumo sobre três sistemas capazes de auxiliar neste diagnóstico: Sistema Especialista, Machine Learning e Deep Learning;
- Estabelecimento de critérios para a escolha do sistema mais adequado;
- Detalhes sobre a realização do diagnóstico valendo-se do sistema escolhido.

2. A INDÚSTRIA 4.0 E O SISTEMA DE DIAGNÓSTICO DE DOENÇAS PULMONARES

2.1. A INDUSTRIA 4.0

Indústria 4.0 ou Quarta Revolução Industrial é uma expressão que engloba algumas tecnologias para automação e troca de dados e utiliza conceitos de Sistemas ciber-físicos, Internet das Coisas[1] e Computação em Nuvem.[2][3][4].

2.2. COMO A INDUSTRIA 4.0 PODE AJUDAR NO DIAGNOSTICO DE DOENCAS PULMONARES

O diagnóstico de doenças pulmonares pode estar sujeito a falhas de interpretação devido ao fato de demandar, além dos exames e das imagens de radiografia extraída do paciente, a interpretação de um profissional. Considerando que diferentes profissionais podem ter diferentes níveis de preparo e condições de avaliação, faz sentido considerar que pareceres diferentes podem ser emitidos para um mesmo resultado.

A indústria 4.0 pode auxiliar nos diagnósticos fornecendo um sistema capaz de emitir pareceres sobre resultados de exames com base em um banco de dados de tamanho significativo a ponto de poder relacionar os exames apresentados com inúmeros outros similares e previamente avaliados.

Cabe salientar que este sistema não visa substituir de forma completa a interpretação realizada pelos profissionais da área de saúde mas sim atuar como auxílio na interpretação dos resultados.

2.3. SISTEMAS EXISTENTES

Existem tecnologias, algumas já não tão recentes, disponíveis na literatura técnica e que destinam-se ao diagnóstico automatizado de doenças diversas. Neste trabalho consideram-se as tecnologias: Sistema Especialista, Machine Learning e Deep Learning. A seguir um resumo sobre cada uma delas.

2.3.1. SISTEMAS ESPECIALISTAS

Sistemas Especialistas são logicas computacionais desenvolvidas com o intuito de resultar em uma resposta para um problema específico, restrito a uma determinada área de conhecimento. Em resumo, um Sistema Especialista funciona de forma similar a um fluxograma, onde as respostas para as perguntas contidas nas caixas de decisão direcionam para uma ou outra sequencia de ações e novas perguntas, finalizando em uma ou outra conclusão ao seu final.

O diferencial que os Sistemas Especialistas apresentam em relação aos programas convencionais é a capacidade de trabalhar com dados qualitativos, ou seja, informações que nem sempre possuem relação direta, tornando difícil a sua representação numérica. Em várias situações, como por exemplo nos diagnósticos

médicos, o conhecimento que guia o profissional nas suas tomadas de decisões é majoritariamente qualitativo e, neste caso, a informação pode ser representada de forma não numérica a partir de símbolos, palavras e frases que seguem determinadas regras. Por outro lado, a obtenção de dados para a elaboração de um Sistema Especialista pode se tornar um desafio devido ao alto grau de subjetividade contido nos dados qualitativos [5] [6].

Sendo assim entende-se que quando houver dados quantitativos disponíveis e suficientes, um Sistema Especialista não será a melhor escolha. Noble [7] elaborou uma tabela onde sugere situações onde o Sistema Especialista é apropriado e onde não é.

TABELA 1 – Algumas situações apropriadas e inapropriadas para o uso de Sistema Especialistas:

Apropriado	Inapropriado
Diagnose Teoria não estabelecida Dados vagos Assunto bem limitado Pouca disponibilidade de especialistas no assunto	Cálculo Fórmulas estabelecidas Dados precisos Assunto não delimitado Conhecimento bem difundido

2.3.2. MACHINE LEARNING

O termo Machine Learning pode ser também encontrado em publicações em português como Aprendizado Automático ou Aprendizado de Máquinas.

O Machine Learning é a área da Engenharia da Computação que trata de desenvolver nos computadores a capacidade de desenvolvimento de lógicas sem que haja uma prévia e explícita programação [8], ou seja, são sistemas capazes de modificar seu comportamento de forma autônoma a partir da própria experiência. Estas lógicas ocorrem a partir da execução de algoritmos que desenvolvem modelos com inputs amostrais e realizam previsões com base nestes modelos, diferentemente de programações convencionais que seguem sempre a mesma pré-programação.

Pode-se dizer, com segurança, que muitos recursos tecnológicos existentes atualmente só são possíveis por causa do Machine Learning, justamente por conta da capacidade em adaptar-se com base em experiências anteriores. Como exemplo pode-se citar:

- Traduções de texto por tradutores automáticos: como as traduções feitas de um idioma para outro não podem ser feitas ao pé da letra, o Machine Learning utiliza os inputs de sucessivas traduções para adaptar contextos, expressões regionais e outros parâmetros tornando as traduções cada vez mais precisas;
- Recomendações de conteúdo: plataformas de streaming de vídeo e áudio utilizam Machine Learning para avaliar as preferências dos usuários e assim sugerir novos conteúdos alinhados com seus gostos.

2.3.3. DEEP LEARNING

O termo Deep Learning pode ser também encontrado em publicações em português como Aprendizado Estruturado Profundo, Aprendizado Hierárquico ou Aprendizado de Máquina Profundo.

O Deep Learning corresponde a uma área específica do Machine Learning que tem por objetivo o desenvolvimento de lógicas capazes de realizar tarefas antes executadas somente por humanos, como reconhecimento de fala e interpretações de imagens.

A maneira como o Deep Learning obtém tais resultados é a partir da configuração de parâmetros básicos sobre dados previamente definidos a fim de que o aprendizado autônomo da máquina possa reconhecer padrões em várias camadas de processamento. Sendo assim, pode-se dizer que o Deep Learning consegue aprender de acordo com o contexto em que é utilizado.

Tecnologias bastante difundidas atualmente como o reconhecimento facial, utilização de veículos autônomos, identificação e classificação de imagens só tornaram-se viáveis devido ao Deep Learning.

Com base no que foi visto até o momento, será elaborada uma matriz de decisão para definir qual das três tecnologias propostas é a mais adequada para integrar-se aos recentes recursos 4.0 e ser utilizada no desenvolvimento do sistema de diagnóstico de doenças pulmonares.

TABELA 2 – Critérios e pesos para a matriz de decisão:

Critérios	Comentários	Pesos		
Facilidade de interpretação pelo usuário	O profissional de saúde precisa interpretar com facilidade os resultados apresentados pelo sistema.	3 Baixo	5 Médio	9 Alto
Capacidade de Aperfeiçoamento	Capacidade do sistema em aperfeiçoar os resultados de forma autônoma conforme aumenta seu banco de dados.	3 Baixo	5 Médio	9 Alto
Configuração do Software	Facilidade de configuração do software.	3 Baixo	5 Médio	9 Alto
Capacidade de processamento de imagens	Capacidade do sistema em interpretar arquivos de imagens.	3 Baixo	5 Médio	9 Alto

TABELA 3 – Matriz de Decisão:

	Cr�terios				Soma dos pesos
	Facilidade de interpreta�o pelo usuario	Capacidade de Aperfeicoamento	Configura�o do Software	Capacidade de processamento de imagens	
Sistema Especialista	3	3	5	3	14
Machine Learning	9	5	9	5	28
Deep Learning	9	9	9	9	36

A matriz de decis o aponta que o melhor sistema a ser utilizado neste caso   o Deep Learning.

3. RESULTADOS E DISCUSSÃO

A seguir apresentam-se os resultados obtidos com os testes realizados durante o desenvolvimento do Deep Learning.

3.1. CONFIGURAÇÃO DO DEEP LEARNING

O algoritmo foi construído utilizando-se o software Anaconda com a versão 3.7.4 do Python, utilizamos a ferramenta Jupyter Notebook para escrever nossos algoritmos, as bibliotecas utilizadas para a construção e análises durante todo o processo foram: 'numpy', 'pandas', 'matplotlib', 'seaborn', 'sklearn', 'keras' e 'tensorflow'.

As imagens desta base de dados estão divididas da seguinte forma: Atelectasia, Cardiomegalia, Consolidação, Edema, Efusão, Enfisema, Fibrose, Hérnia, Infiltração, Massa, Nódulo, Espessamento pleural, Pneumonia, Pneumotórax e imagens sem estas doenças detectadas, porém algumas imagens podem possuir mais que uma doença. Estas imagens que não foram encontradas estas doenças, não se pode dizer que não exista algum tipo de problema, mas que não é presente as doenças anteriormente citadas.

O algoritmo é capaz de prever a(s) doença(s) presente(s) no exame com a acuracidade de 87,86%. A acuracidade é diretamente impactada de acordo com a quantidade de imagens disponíveis para o treinamento e validação do modelo. Nesta construção não havia imagens suficientes para que pudéssemos aprimorar mais o algoritmo para algumas doenças, fazendo com que o modelo não alcançasse um valor alto de acuracidade.

Além da quantidade de imagens de algumas doenças não serem o suficiente para conseguirmos aprimorar mais nosso algoritmo, o poder computacional também influencia no resultado, já que para poder fazer o algoritmo com uma quantidade muito grande de imagens e também o tamanho de cada imagem, faz com que seja muito demorado todo o processamento. No nosso modelo final de treinamento, o qual possuiu a maior acuracidade, o computador processou todo algoritmo em aproximadamente 6 horas, considerando que nossa base original tinha cerca de 112 mil imagens em 45Gb.

Construímos o algoritmo com a técnica de classificação 'Multi-label Image Classification', no qual um objeto pode possuir mais de uma classificação, utilizando este relato, significa que um raio-x pode haver mais de uma doença presente.

Sendo assim, carregamos um arquivo no formato 'csv' relacionando os nomes dos arquivos das imagens com os diagnósticos presentes no 'csv', desta forma ao realizar o treinamento e validação, o algoritmo consegue identificar o padrão nas imagens quando existe um ou mais tipos de doença e qual doença pode ser, desta forma ao testarmos uma imagem que possua mais de uma doença e que ele não tenha utilizado no treinamento, será possível prever com uma boa acuracidade.

Desta forma, quando uma imagem é processada, o algoritmo irá perceber o padrão dela, como se comporta na situação de alguma doença, e assim conseguirá identificar de forma sozinha como é um exame com diagnóstico positivo de tal doença.

Este tipo de aprendizado, é conhecido como supervisionado, pois damos os dados de forma rotulada, com a definição de qual padrão ele irá definir para aquele tipo de dado com este rótulo, ou seja, possui uma variável definida pelo usuário.

Nas imagens a seguir podemos verificar os resultados do teste de 6 imagens, no qual não haviam sido utilizadas durante a construção e mesmo foi possível prever todas corretas, de acordo com o diagnóstico original:


Diagnóstico: Effusi, Pleura, Pneumo
Diag_Algoritmo: Effusi, Pleura, Pneumo



Diagnóstico: Consol
Diag_Algoritmo: Consol



Diagnóstico: Nodule
Diag_Algoritmo: Nodule



Diagnóstico: Effusi
Diag_Algoritmo: Effusi



Diagnóstico: Consol
Diag_Algoritmo: Consol



Diagnóstico: Atelec, Effusi, Infil
Diag_Algoritmo: Atelec, Effusi, Infil



FIGURA 1 – Teste de imagens de raio-x

4. CONSIDERAÇÕES FINAIS

Neste trabalho apresentaram-se conceitos relacionados à análise computadorizada das imagens pulmonares, incluindo aspectos de inteligência artificial aplicada à medicina de precisão.

Este trabalho agrega aspectos positivos tanto para a sociedade como para a universidade. Para a sociedade este sistema se traduz como um trabalho baseado em tecnologias atuais, desenvolvido de forma gratuita sob a orientação dos professores da UFPR e que chega na hora certa para auxiliar populações que nem sempre dispõem de fácil acesso a um diagnóstico preciso. Para a universidade existe o enriquecimento do seu banco de trabalhos com mais um exemplar dedicado a um sistema de diagnóstico que utiliza tecnologia 4.0.

No entanto, vale salientar que mesmo diante dos aspectos positivos deste trabalho, existe o risco de ser sua implementação encontrar dificuldades principalmente nas fases iniciais de implementação, podendo enfrentar um certo descrédito por parte dos profissionais e pacientes, porém acredita-se que na medida em que tone-se mais conhecido ao longo do tempo, este descrédito diminua e seus aspectos positivos tornem-se cada vez mais reconhecidos e aceitos.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] The 2016 World Economic Forum Misfires With Its Fourth Industrial Revolution Theme
- [2] Hermann, Pentek, Otto, 2015: Design Principles for Industrie 4.0 Scenarios
- [3] Jürgen Jasperneite: Was hinter Begriffen wie Industrie 4.0 steckt in Computer & Automation, 19 Dezember 2012
- [4] Kagermann, H., W. Wahlster and J. Helbig, eds., 2013: Recommendations for implementing the strategic initiative Industrie 4.0: Final report of the Industrie 4.0 Working Group
- [5] Waldrop, M.M. The necessity of knowledge. Science, 223(4642): 1279-1282. 1984.
- [6] Hart, A. Knowledge Acquisition for Expert Systems. London, Kogan Page, 1986. 180 p.
- [7] Noble, I.R. The role of expert systems in vegetation science. Vegetation, 69: 115-121. 1987.
- [8] Simon, Phil (Março, 18, 2013). Too Big to Ignore: The Business Case for Big Data. [S.l.]: Wiley. 89 páginas. ISBN 978-1-118-63817-0