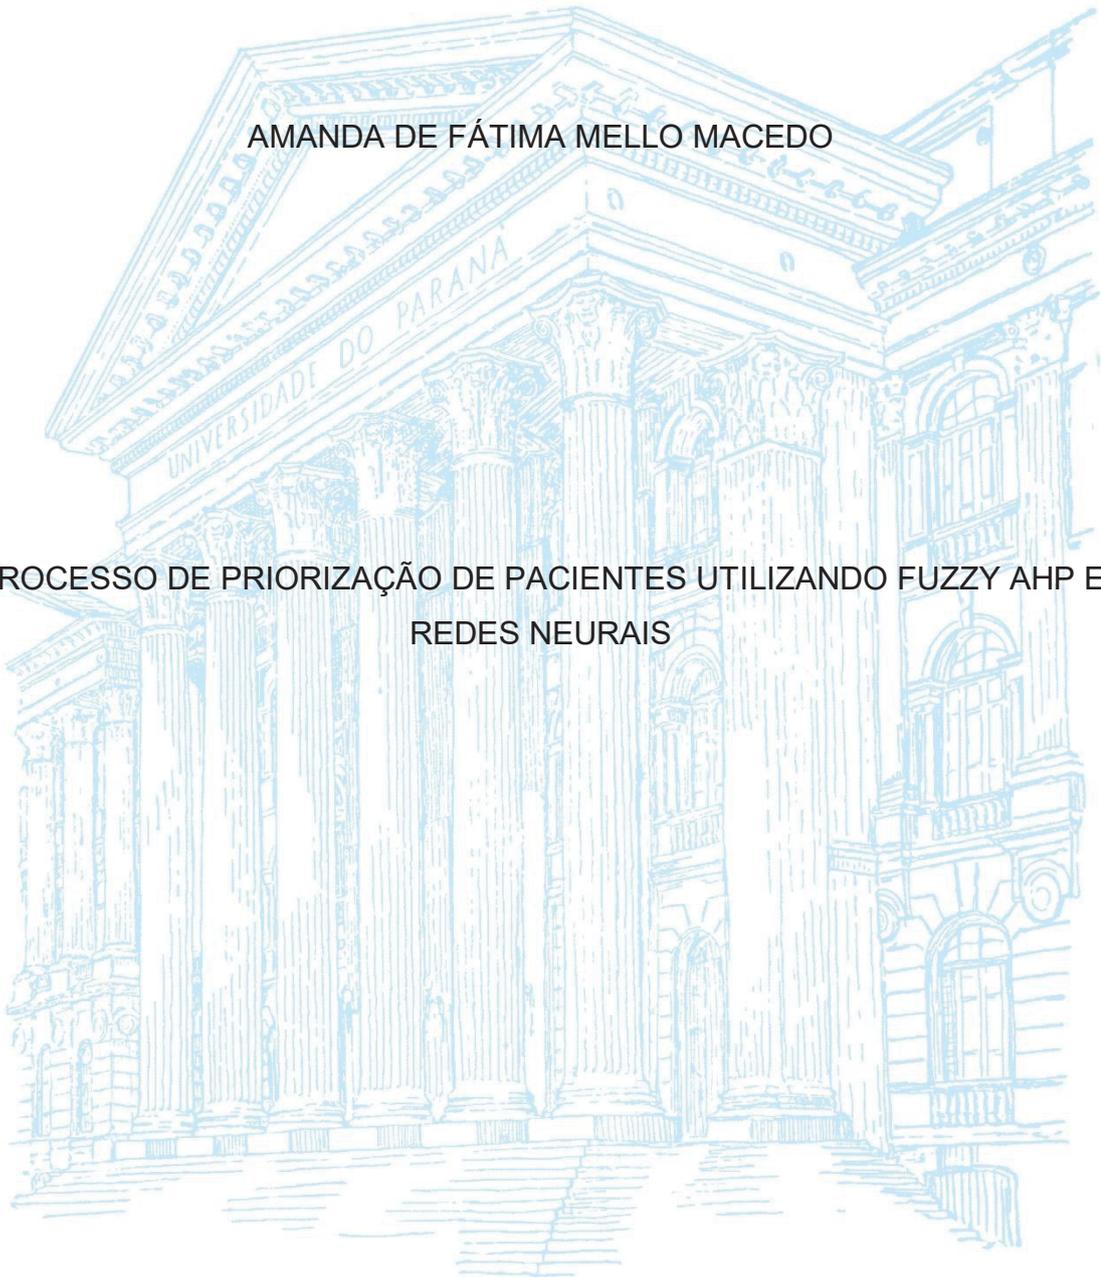


UNIVERSIDADE FEDERAL DO PARANÁ

AMANDA DE FÁTIMA MELLO MACEDO

PROCESSO DE PRIORIZAÇÃO DE PACIENTES UTILIZANDO FUZZY AHP E
REDES NEURAIS



CURITIBA

2024

AMANDA DE FÁTIMA MELLO MACEDO

PROCESSO DE PRIORIZAÇÃO DE PACIENTES UTILIZANDO FUZZY AHP E
REDES NEURAIS

Tese apresentada ao curso de Pós-Graduação em Métodos Numéricos em Engenharia, área de concentração Programação Matemática, Setor de Ciências Exatas, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Doutor em Métodos Numéricos em Engenharia.

Orientador: Prof. Dr. José Eduardo Pécora Junior

CURITIBA

2024

DADOS INTERNACIONAIS DE CATALOGAÇÃO NA PUBLICAÇÃO (CIP)
UNIVERSIDADE FEDERAL DO PARANÁ
SISTEMA DE BIBLIOTECAS – BIBLIOTECA DE CIÊNCIA E TECNOLOGIA

Macedo, Amanda de Fátima Mello

Processo de priorização de pacientes utilizando Fuzzy AHP e redes neurais / Amanda de Fátima Mello Macedo. – Curitiba, 2024.

1 recurso on-line : PDF.

Tese (Doutorado) - Universidade Federal do Paraná, Setor de Ciências Exatas, Programa de Pós-Graduação em Métodos Numéricos em Engenharia.

Orientador: José Eduardo Pécora Junior

1. Pacientes. 2. COVID-19 (Doença). 3. Nefrolitotripsia Percutânea. 4. Redes neurais (Computação). 5. Processo de hierarquia analítica Fuzzy. I. Universidade Federal do Paraná. II. Programa de Pós-Graduação em Métodos Numéricos em Engenharia. III. Pécora Junior, José Eduardo. IV. Título.

Bibliotecário: Elias Barbosa da Silva CRB-9/1894

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação MÉTODOS NUMÉRICOS EM ENGENHARIA da Universidade Federal do Paraná foram convocados para realizar a arguição da tese de Doutorado de **AMANDA DE FÁTIMA MELLO MACEDO** intitulada: **PROCESSO DE PRIORIZAÇÃO DE PACIENTES UTILIZANDO FUZZY AHP E REDES NEURAIS**, sob orientação do Prof. Dr. JOSÉ EDUARDO PÉCORA JUNIOR, que após terem inquirido a aluna e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de doutora está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

Curitiba, 05 de Novembro de 2024.

Assinatura Eletrônica
27/11/2024 20:34:33.0
JOSÉ EDUARDO PÉCORA JUNIOR
Presidente da Banca Examinadora

Assinatura Eletrônica
02/12/2024 19:36:39.0
EDUARDO ALVES PORTELA SANTOS
Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica
28/11/2024 16:11:59.0
JOSÉ ROBERTO FREGA
Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica
27/11/2024 15:45:33.0
EDUARDO DE FREITAS ROCHA LOURES
Avaliador Externo (PONTIFICA UNIVERSIDADE CATÓLICA DO PARANÁ)

Ao meu amado pai, Getúlio (in memoriam).

AGRADECIMENTOS

Em primeiro lugar, ao Deus triúno, que é o Senhor da minha vida e que permitiu que eu chegasse até aqui. Toda honra e glória sejam dadas a Ele eternamente.

À toda a minha família, que sempre me apoiou, me sustentou e lutou junto comigo. Agradeço por toda paciência, cuidado, ajuda e amor. Em especial, agradeço ao meu pai Getúlio, à minha irmã Fernanda, ao meu cunhado Filipe, aos meus sobrinhos Talita, Daniel e o Josué, à minha mãe Madalena, ao Tito (Pedro), ao meu irmão Pedro Henrique e à Scheila.

Ao meu namorado Diogo, pelo apoio, incentivo, amor, carinho e paciência que sempre demonstrou. Aos irmãos em Cristo, que me sustentam em orações e me cercam com seus cuidados e amor. A todos os meus amigos, pelo amor e parceria. Guardo todos no coração com muito carinho e sou grata por terem me apoiado e acreditado em mim.

Ao meu orientador, Prof. Dr. José Eduardo Pécora, por acreditar em mim e por ser um excelente profissional. Agradeço por sua disposição, apoio acadêmico e emocional e por estar sempre pronto para ajudar.

Aos colegas, amigos e professores do grupo de pesquisa GTA0, do projeto de priorização de pacientes com Covid-19 e do projeto de pedra nos rins. Agradeço por todas as reuniões e conversas, as quais foram essenciais para o meu crescimento e para que eu pudesse concluir esse trabalho.

Aos meus professores, que foram essenciais na minha jornada escolar e acadêmica. Em especial, ao Cássio e ao Celso, por terem me incentivado e me inspirado a seguir na área de matemática, durante o Ensino Médio. E a minha orientadora da graduação Profa. Andréia Büttner Ciani, pela força e amizade que sempre ofereceu a mim.

Aos professores integrantes da banca examinadora, Prof. Dr. José Roberto Frega, Prof. Dr. Eduardo Alves Portela e Prof. Dr. Eduardo Loures pela disponibilidade e pelas ótimas contribuições sugeridas ao trabalho.

Ó profundidade das riquezas, tanto da sabedoria, como da ciência de Deus! Quão insondáveis são os seus juízos, e quão inescrutáveis os seus caminhos!
Por que quem compreendeu a mente do Senhor? ou quem foi seu conselheiro?
Ou quem lhe deu primeiro a ele, para que lhe seja recompensado?
Porque DELE e por ELE, e para ELE, são todas as coisas; glória, pois, a ele eternamente. Amém. Romanos 11: 33-36.

RESUMO

A superlotação de hospitais e as longas filas para cirurgias, exames, consultas e outros serviços de saúde têm sido um problema no Brasil e em diversos países. Neste trabalho, serão abordados dois problemas que geram filas de espera nos hospitais: o problema da superlotação de hospitais devido a pandemia da Covid-19 e o problema da fila de espera para a realização de uma cirurgia para tratamento de pedra nos rins (Nefrolitotripsia Percutânea). Diante desses desafios, será proposto um processo de priorização de pacientes considerando o problema da COVID-19 e o problema da cirurgia de Nefrolitotripsia Percutânea. Além disso, será proposta uma abordagem de redes neurais para classificação e priorização dos pacientes da fila de espera da Nefrolitotripsia Percutânea. O processo de priorização conta com as etapas de definição dos objetivos da pesquisa, definição dos critérios por meio de uma revisão da literatura, convergência dos critérios utilizando o método Delphi, cálculo das prioridades dos critérios com o método *Fuzzy Analytic hierarchy process* (FAHP), coleta de dados dos pacientes e prioridades dos pacientes. A abordagem de redes neurais proposta está dividida em duas partes, a primeira parte para classificar os pacientes em três grupos de prioridade (alta, média e baixa), e a segunda parte para priorizar os pacientes de cada um desses grupos, de acordo com a priorização obtida com o FAHP. A abordagem de redes neurais também poderá ser utilizada para previsão da classificação e da priorização de pacientes que possam ser incluídos na fila de espera para a cirurgia. Os resultados apresentaram a priorização dos critérios e dos pacientes para a Nefrolitotripsia Percutânea e a melhor configuração de redes neurais para a abordagem proposta. Os subcritérios com maiores pesos foram “DOI” (disfunção orgânica importante), “AFR” (agravo a função renal), “GUY4_4” (quadro cirúrgico complexo com *Guy’s Score* 4 nos dois rins), “Rim_trans” (um rim transplantado), “Nefrostomia”, “Duploj” (cateter duplo J) e “DOR” (dor de difícil manejo clínico). A hidronefrose foi o subcritério que os pacientes mais apresentaram e foi possível obter uma nova ordem de pacientes para a fila de espera para a Nefrolitotripsia Percutânea. A configuração de rede neural que apresentou os melhores resultados na primeira parte, apresentou um erro média de 13% e uma acurácia de média de 90%. E a rede neural que obteve o melhor resultado na segunda parte, apresentou um erro médio de 5% e uma acurácia média de 98%.

Palavras-chave: Priorização de Pacientes; Fuzzy AHP; Redes Neurais Artificiais; Covid-19; Nefrolitotripsia Percutânea.

ABSTRACT

The overcrowding of hospitals and long wait times for surgeries, exams, consultations, and other healthcare services have been persistent issues in Brazil and many other countries. This work addresses two key problems that contribute to hospital waitlists: the issue of hospital overcrowding due to the COVID-19 pandemic and the waitlist for kidney stone treatment surgery (Percutaneous Nephrolithotripsy). In response to these challenges, a patient prioritization process is proposed, considering these two issues, along with a neural network approach for the classification and prioritization of patients on the Percutaneous Nephrolithotripsy waitlist. The prioritization process involves several steps: defining the research objectives, establishing criteria through a literature review, converging criteria using the Delphi method, calculating the criteria priorities with the Fuzzy Analytic Hierarchy Process (FAHP), collecting patient data, and determining patient priorities. The proposed neural network approach is divided into two parts. The first part classifies patients into three priority groups (high, medium, and low), and the second part prioritizes patients within each group based on the prioritization obtained from FAHP. The neural network approach can also be used to predict the classification and prioritization of new patients. The results presented the prioritization of criteria and patients for Percutaneous Nephrolithotripsy and the optimal neural network configuration for the proposed approach. The subcriteria with the highest weights were "DOI," "AFR," "GUY4_4," "Rim_trans," "Nephrostomy," "Double J," and "Pain." Hydronephrosis was the most common subcriterion among patients, and a new patient order was established for the Percutaneous Nephrolithotripsy waitlist. The neural network configuration that yielded the best results in the first part had an average error of 13% and an average accuracy of 90%. The neural network that performed best in the second part had an average error of 5% and an average accuracy of 98%.

Keywords: Patient Prioritization; Fuzzy AHP; Artificial Neural Networks; COVID-19; Percutaneous Nephrolithotripsy.

LISTA DE FIGURAS

FIGURA 1 - HIERARQUIA DO MÉTODO AHP.....	66
FIGURA 2 - FUNÇÃO DE PERTINÊNCIA DE UM NÚMERO FUZZY TRIANGULAR.....	69
FIGURA 3 – ESQUEMA DO PERCEPTRON DE UMA CAMADA.....	73
FIGURA 4 – EXEMPLO DE PROBLEMA LINEARMENTE SEPARÁVEL	78
FIGURA 5 – EXEMPLO DE PROBLEMA NÃO LINEARMENTE SEPARÁVEL	78
FIGURA 6 – EXEMPLO DE PERCEPTRON MULTICAMADAS	79
FIGURA 7 - FLUXOGRAMA DAS ETAPAS DA PRIORIZAÇÃO.....	81
FIGURA 8 - PASSOS DA ETAPA DE DEFINIÇÃO DOS CRITÉRIOS DE PRIORIZAÇÃO	82
FIGURA 9 – PASSOS DA ETAPA DE AVALIAÇÃO	84
FIGURA 10 - ESQUEMA DA BUSCA DOS CRITÉRIOS DE GRAVIDADE DA COVID-19 NA LITERATURA.....	89
FIGURA 11 - HIERARQUIA DOS CRITÉRIOS	95
FIGURA 12 - PERGUNTAS DO QUESTIONÁRIO APLICADO AOS ESPECIALISTAS	95
FIGURA 13 – ESQUEMA DOS EXPERIMENTOS COMPUTACIONAIS ALTERANDO A ARQUITETURA DA REDE E AS FUNÇÕES DE ATIVAÇÃO	110
FIGURA 14 - ESQUEMA DOS EXPERIMENTOS COMPUTACIONAIS ALTERANDO O NÚMERO DE ÉPOCAS	111
FIGURA 15 - ESQUEMA DOS EXPERIMENTOS COMPUTACIONAIS ALTERANDO A TAXA DE APRENDIZAGEM.....	112
FIGURA 16 - HIERARQUIA COM O RESULTADO DA PRIORIZAÇÃO DOS CRITÉRIOS.....	114
FIGURA 17 - GRÁFICOS DE BARRAS COM O PESO DE CADA CRITÉRIO	114
FIGURA 18 - GRÁFICOS DE RADAR COMPARANDO O RESULTADO DE UM ESPECIALISTA COM O RESULTADO DO GRUPO TODO	116
FIGURA 19 - GRÁFICOS DE BARRAS COM A FREQUÊNCIA DOS PACIENTES EM RELAÇÃO A CADA CRITÉRIO	118
FIGURA 20 – RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_1, ARQUI_1, FUNÇÃO ELU, 300 ÉPOCAS E TAXA DE APRENDIZAGEM 0,001	122
FIGURA 21 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_21, ARQUI_2, FUNÇÃO ELU	124
FIGURA 22 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_22, ARQUI_2, FUNÇÃO ELU	125
FIGURA 23 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_23, ARQUI_2, FUNÇÃO LEAKY RELU	126
FIGURA 24 – RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_1, ARQUI_1 E FUNÇÃO RELU.....	149
FIGURA 25 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_1, ARQUI_1 E FUNÇÃO ELU	149
FIGURA 26 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_1, ARQUI_1 E FUNÇÃO LEAKY RELU	150

FIGURA 27 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_1, ARQUI_2 E FUNÇÃO RELU.....	151
FIGURA 28 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_1, ARQUI_2 E FUNÇÃO ELU	151
FIGURA 29 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_1, ARQUI_2 E FUNÇÃO LEAKY RELU	152
FIGURA 30 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_1, ARQUI_3 E FUNÇÃO RELU.....	153
FIGURA 31 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_1, ARQUI_3 E FUNÇÃO EL.....	153
FIGURA 32 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_1, ARQUI_3 E FUNÇÃO LEAKY RELU	154
FIGURA 33 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_1, ARQUI_1, FUNÇÃO ELU E 100 ÉPOCAS	154
FIGURA 34 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_1, ARQUI_1, FUNÇÃO ELU E 500 ÉPOCAS	155
FIGURA 35 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_1, ARQUI_1, FUNÇÃO ELU, 300 ÉPOCAS E TAXA DE APRENDIZAGEM 0,1	156
FIGURA 36 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_1, ARQUI_1, FUNÇÃO ELU, 300 ÉPOCAS E TAXA DE APRENDIZAGEM 0,01	156
FIGURA 37 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_21, ARQUI_1, FUNÇÃO RELU.....	157
FIGURA 38 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_22, ARQUI_1, FUNÇÃO RELU.....	158
FIGURA 39 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_23, ARQUI_1, FUNÇÃO RELU.....	158
FIGURA 40 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_21, ARQUI_1, FUNÇÃO ELU	159
FIGURA 41 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_22, ARQUI_1, FUNÇÃO ELU	160
FIGURA 42 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_23, ARQUI_1, FUNÇÃO ELU	160
FIGURA 43 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_21, ARQUI_1, FUNÇÃO LEAKY RELU	161
FIGURA 44 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_22, ARQUI_1, FUNÇÃO LEAKY RELU	162
FIGURA 45 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_23, ARQUI_1, FUNÇÃO LEAKY RELU	162
FIGURA 46 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_21, ARQUI_2, FUNÇÃO RELU.....	163

FIGURA 47 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_22, ARQUI_2, FUNÇÃO RELU.....	164
FIGURA 48 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_23, ARQUI_2, FUNÇÃO RELU.....	164
FIGURA 49 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_21, ARQUI_2, FUNÇÃO ELU	165
FIGURA 50 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_22, ARQUI_2, FUNÇÃO ELU	166
FIGURA 51 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_23, ARQUI_2, FUNÇÃO ELU	166
FIGURA 52 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_21, ARQUI_2, FUNÇÃO LEAKY RELU	167
FIGURA 53 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_22, ARQUI_2, FUNÇÃO LEAKY RELU	168
FIGURA 54 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_23, ARQUI_2, FUNÇÃO LEAKY RELU	168
FIGURA 55 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_21, ARQUI_3, FUNÇÃO RELU.....	169
FIGURA 56 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_22, ARQUI_3, FUNÇÃO RELU.....	170
FIGURA 57 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_23, ARQUI_3, FUNÇÃO RELU.....	170
FIGURA 58 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_21, ARQUI_3, FUNÇÃO ELU	171
FIGURA 59 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_22, ARQUI_3, FUNÇÃO ELU	172
FIGURA 60 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_23, ARQUI_3, FUNÇÃO ELU	172
FIGURA 61 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_21, ARQUI_3, FUNÇÃO LEAKY RELU	173
FIGURA 62 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_22, ARQUI_3, FUNÇÃO LEAKY RELU	174
FIGURA 63 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_23, ARQUI_3, FUNÇÃO LEAKY RELU	174
FIGURA 64 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_21, ARQUI_2, FUNÇÃO ELU E 100 ÉPOCAS	175
FIGURA 65 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_22, ARQUI_2, FUNÇÃO ELU E 100 ÉPOCAS	176
FIGURA 66 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_23, ARQUI_2, FUNÇÃO LEAKY RELU E 100 ÉPOCAS	177

FIGURA 67 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_21, ARQUI_2, FUNÇÃO ELU E 500 ÉPOCAS	177
FIGURA 68 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_22, ARQUI_2, FUNÇÃO ELU E 500 ÉPOCAS	178
FIGURA 69 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_23, ARQUI_2, FUNÇÃO LEAKY RELU E 500 ÉPOCAS	178
FIGURA 70 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_21, ARQUI_2, FUNÇÃO ELU, 300 ÉPOCAS E TAXA DE APRENDIZAGEM 0,1	179
FIGURA 71 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_22, ARQUI_2, FUNÇÃO ELU, 300 ÉPOCAS E TAXA DE APRENDIZAGEM 0,1	180
FIGURA 72 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_23, ARQUI_2, FUNÇÃO LEAKY RELU, 300 ÉPOCAS E TAXA DE APRENDIZAGEM 0,1	180
FIGURA 73 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_21, ARQUI_2, FUNÇÃO ELU, 300 ÉPOCAS E TAXA DE APRENDIZAGEM 0,01	181
FIGURA 74 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_22, ARQUI_2, FUNÇÃO ELU, 300 ÉPOCAS E TAXA DE APRENDIZAGEM 0,01	182
FIGURA 75 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_22, ARQUI_2, FUNÇÃO LEAKY RELU, 300 ÉPOCAS E TAXA DE APRENDIZAGEM 0,01	182

LISTA DE QUADROS

QUADRO 1 - TRABALHOS QUE ABORDARAM PROBLEMAS DE PRIORIZAÇÃO UTILIZANDO O MÉTODO AHP	32
QUADRO 2 - TRABALHOS QUE ABORDARAM PROBLEMAS DE PRIORIZAÇÃO UTILIZANDO MÉTODOS DE INTELIGÊNCIA ARTIFICIAL.....	56
QUADRO 3 - CRITÉRIOS DETERMINADOS PELA REVISÃO NA LITERATURA	90
QUADRO 4 - ESCALA DE JULGAMENTOS DE SAATY E NÚMEROS TRIANGULARES FUZZY	96
QUADRO 5 - COMPARAÇÃO PAR A PAR DOS PESOS DOS CRITÉRIOS COM OS VALORES DA ESCALA DE SAATY PARA O CRITÉRIO “AGRAVOS RELACIONADOS A INFECÇÃO OU COMORBIDADES”.	97
QUADRO 6 - COMPARAÇÃO PAR A PAR DOS PESOS DOS CRITÉRIOS COM NÚMEROS TRIANGULARES FUZZY, PARA O CRITÉRIO “AGRAVOS RELACIONADOS A INFECÇÃO OU COMORBIDADES”.	97
QUADRO 7 - MATRIZ COM OS DADOS DOS PACIENTES REFERENTES AOS CRITÉRIOS.....	98
QUADRO 8 - PRIORIDADE DOS CRITÉRIOS.....	101
QUADRO 9 – COMPARAÇÃO ENTRE AS PRIORIZAÇÕES DO FAHP E DO ESPECIALISTA NA PRIMEIRA RODADA	102
QUADRO 10 - DESCRIÇÃO DAS RODADAS DA VALIDAÇÃO DO MÉTODO	105
QUADRO 11 - NOVOS PESOS PARA O CRITÉRIO “CRITÉRIOS PRIMÁRIOS”	106
QUADRO 12 - NOVOS PESOS PARA O CRITÉRIO “AGRAVOS RELACIONADOS A FUNÇÃO RENAL”	106
QUADRO 13 - EXEMPLO DO CONJUNTO DE DADOS DA REDE NEURAL RN_1.	108
QUADRO 14 - EXEMPLO DOS CONJUNTOS DE DADOS DAS REDES NEURAS RN_21, RN_22, RN_23 ..	109
QUADRO 15 – RESULTADO DA PRIORIZAÇÃO DOS CRITÉRIOS	113
QUADRO 16 – RESULTADO DA PRIORIZAÇÃO COM FAHP	119

SUMÁRIO

1	INTRODUÇÃO	15
1.1	OBJETIVO GERAL.....	17
1.2	OBJETIVOS ESPECÍFICOS.....	17
1.3	JUSTIFICATIVA	17
1.4	LIMITAÇÕES DO TRABALHO	18
1.5	ESTRUTURA DO TRABALHO	19
2	REFERENCIAL TEÓRICO	20
2.1	PROCESSO HIERÁRQUICO ANALÍTICO – AHP	23
2.1.1	Busca na Web of Science.....	23
2.1.2	Busca na Scopus.....	23
2.1.3	AHP na Priorização de Pacientes em <i>Healthcare</i>	24
2.2	INTELIGÊNCIA ARTIFICIAL – IA	37
2.2.1	Busca na Web of Science.....	37
2.2.2	Busca na Scopus.....	37
2.2.3	Inteligência Artificial na Priorização de Pacientes em Healthcare	37
3	MÉTODO FUZZY AHP	65
3.1	ANALYTIC HIERARCHY PROCESS – AHP	65
3.2	CONJUNTO FUZZY	66
3.3	MÉTODO FUZZY ANALYTIC HIERARCHY PROCESS - FAHP.....	67
4	REDES NEURAIS ARTIFICIAIS.....	72
4.1	PERCEPTRON DE UMA CAMADA.....	72
4.2	ERRO	75
4.3	ATUALIZAÇÃO DOS PESOS.....	77
4.4	REDES MULTICAMADAS	77
4.5	DESCIDA DO GRADIENTE E BACKPROPAGATION.....	79
5	METODOLOGIA.....	80
5.1	DEFINIÇÃO DOS OBJETIVOS DO ESTUDO.....	81
5.2	DEFINIÇÃO DOS CRITÉRIOS DE PRIORIZAÇÃO	82
5.3	AVALIAÇÃO	83
5.4	VERIFICAÇÃO E VALIDAÇÃO.....	85
5.5	IMPLEMENTAÇÃO.....	85
5.6	ABORDAGEM DE REDES NEURAIS	86
6	PROCESSO DE PRIORIZAÇÃO DE PACIENTES COM FAHP	87
6.1	DEFINIÇÃO DOS OBJETIVOS DO ESTUDO.....	87
6.1.1	Covid-19	87
6.1.2	NLPC	87
6.2	DEFINIÇÃO DOS CRITÉRIOS DE PRIORIZAÇÃO	88
6.2.1	Covid-19	88
6.2.2	NLPC	93
6.3	AVALIAÇÃO	93
6.3.1	Agrupamento dos critérios	93
6.3.2	Estrutura hierárquica	94
6.3.3	Questionário AHP	95
6.3.4	Coleta de dados dos especialistas.....	96
6.3.5	Cálculo dos pesos	97
6.3.6	Coleta de dados dos pacientes.....	98
6.3.7	Cálculo do escore de gravidade (priorização dos pacientes)	98
6.4	VERIFICAÇÃO E VALIDAÇÃO.....	100
6.4.1	Verificação (cálculo dos pesos)	100

6.4.2	Validação.....	102
6.5	IMPLEMENTAÇÃO.....	106
7	ESTRUTURA DE REDE NEURAL PROPOSTA	107
7.1	PRIMEIRA PARTE	107
7.2	SEGUNDA PARTE	108
7.3	EXPERIMENTOS COMPUTACIONAIS	110
8	RESULTADOS	113
8.1	PRIORIZAÇÃO DOS CRITÉRIOS.....	113
8.2	PRIORIZAÇÃO DOS PACIENTES	117
8.3	ABORDAGEM DE REDES NEURAIS	120
8.3.1	Primeira Parte (RN_1)	121
8.3.2	Segunda Parte (RN_21, RN_22 e RN_23)	123
9	CONSIDERAÇÕES FINAIS.....	128
	REFERÊNCIAS	130
	GLOSSÁRIO	138
	APÊNDICE 1 – RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA	
	ABORDAGEM DE REDES NEURAIS	148

1 INTRODUÇÃO

Casos de superlotação de hospitais, filas para cirurgias e para procedimentos médicos são comuns nos sistemas de saúde. Isso ocorre por falta de verba, materiais, espaço, pessoal, dentre outros. Dessa forma, utilizar mecanismos para enfrentar esses problemas pode ser um auxílio aos pacientes que necessitem de algum atendimento hospitalar com urgência e estão em filas de espera. Em muitos casos, esses pacientes podem esperar nessas filas por meses ou até anos. Por outro lado, pode haver nessas filas, pacientes que não possuem tanta urgência de atendimento, os quais poderiam esperar para serem atendidos, sem grandes danos à saúde. O processo de priorização de pacientes pode ajudar nessas situações, utilizando métodos multicritério em conjunto com a opinião de especialistas na área de saúde e métodos de inteligência artificial.

Nesse cenário, Thokala et al. (2016) mencionam que os métodos multicritério de apoio à decisão (MMAD) pode apoiar a decisão de profissionais da área da saúde, melhorando a transparência, consistência e legitimidade das decisões. Segundo os autores, esse processo não substitui o julgamento desses profissionais, mas necessita de um trabalho em conjunto, fornecendo suporte e estrutura ao processo. Özkan et al. (2021) defendem que a MMAD é adequada para priorização de pacientes com COVID-19, devido à escassez de leitos hospitalares em decorrência da pandemia. Segundo os autores, uma abordagem deveria ser utilizada para apresentar recomendações que possam identificar e priorizar esses pacientes para ocuparem leitos de UTI, pois essa admissão envolve fatores conflitantes na tomada de decisão.

Jiang et al. (2017) mencionam que sistemas de Inteligência Artificial (IA) podem auxiliar os médicos no gerenciamento de grandes conjuntos de dados, fornecendo informações atualizadas. Outra contribuição desses sistemas é na realização de inferências em tempo real sobre as condições de saúde dos pacientes. Além disso, de acordo com os autores, os métodos de inteligência artificial podem ajudar a reduzir erros nos diagnósticos dados aos pacientes. Sahni et al. (2023) também falam dos benefícios da IA em saúde, destacando economias financeiras que podem ocorrer ao longo do tempo, ao ser estabelecido um sistema de IA, sem perder a qualidade no atendimento aos pacientes.

Neste trabalho, serão mencionados dois problemas que geram filas de espera de pacientes e que necessitam de uma reorganização da ordem desses pacientes nas filas. O primeiro problema é sobre a priorização de pacientes com COVID-19 que necessitem de hospitalização e o segundo problema se trata da priorização de pacientes na fila de espera para uma cirurgia para tratamento de pedra nos rins, de Nefrolitotripsia Percutânea.

A pandemia do novo coronavírus se tornou um problema mundial entre os anos de 2019-2022. Devido a quantidade de infectados, os leitos de UTI de hospitais em todo o mundo apresentaram altas taxas de ocupação, impossibilitando que alguns pacientes recebessem o cuidado necessário para o tratamento da COVID-19, gerando discussões acerca de quais grupos de pacientes apresentariam prioridades no internamento em comparação com outros. Segundo Fiocruz (2021), em um boletim extraordinário sobre a COVID-19 divulgado em 16 de março de 2021, essas altas taxas denotaram um colapso do sistema de saúde, prejudicando os pacientes que necessitavam de atendimento urgente devido a Covid-19. Desta forma, a priorização desses pacientes poderia aumentar as chances de sobrevivência de um número maior de pessoas, tendo em vista que a falta de atendimento necessário, devido a superlotação, foi um causador de óbitos em decorrência da gravidade da doença.

O Complexo Hospital de Clínicas de Curitiba (CHC) é referência no Paraná para tratamento de pedra nos rins (litíase urinária) pelo SUS. Mas, embora sejam realizadas muitas cirurgias, ainda há uma grande demanda, não sendo suportada pela sua capacidade de atendimento, causando atrasos e filas de espera para as cirurgias. A cirurgia de Nefrolitotripsia Percutânea (NLPC) é o principal tratamento com fila de espera na urologia do CHC.

Dessa forma, este trabalho traz uma proposta de um processo priorização de pacientes, que pode ser adaptado a qualquer problema de priorização, e uma abordagem de redes neurais para contribuir com essa priorização. No caso desse trabalho, dois métodos foram combinados, seguindo a ideia de *ensemble*, com o intuito de melhorar a precisão dos resultados. Na pesquisa de Kim et al. (2024), a técnica *ensemble* realizou previsões mais precisas do que as previsões de modelos únicos. Para isso, os métodos utilizados foram o método multicritério *Fuzzy Analytic Hierarchy Process* (FAHP) e as Redes Neurais Artificiais, porém essa é uma abordagem flexível, permitindo que os métodos sejam aplicados individualmente, se necessário.

Nesse contexto, o processo é exemplificado pelo problema da COVID-19 e pelo problema da cirurgia NLPC, sendo as etapas ilustradas por ambos os problemas ou por apenas um deles, assim como a abordagem de redes neurais. Para isso, serão definidos os objetivos da pesquisa (COVID-19 e NLPC) e selecionados critérios de gravidade com base na literatura (COVID-19). Após, será realizada a priorização utilizando Fuzzy AHP(NLPC), seguida da validação e verificação do método (NLPC). Em trabalhos futuros, o método será implementado, resultando em uma nova lista de pacientes organizada conforme a prioridade estabelecida. A abordagem de redes neurais será empregada para classificar os pacientes em grupos de prioridade e refiná-los dentro desses grupos, ajustando suas posições conforme o método (NLPC). Além disso, em trabalhos futuros, as redes neurais poderão ser utilizadas para prever tanto o grupo quanto a posição de um novo paciente na fila de espera.

1.1 OBJETIVO GERAL

Desenvolver e validar uma metodologia de priorização de pacientes para diferentes contextos clínicos, utilizando técnicas baseadas em critérios bem definidos e métodos de inteligência artificial para otimizar a gestão da fila de espera.

1.2 OBJETIVOS ESPECÍFICOS

- Realizar uma revisão da literatura para identificar os métodos de priorização de pacientes, os critérios mais comuns e os resultados obtidos em estudos anteriores.
- Definir e estruturar critérios de priorização baseados na literatura e no consenso de especialistas.
- Aplicar e demonstrar a metodologia de priorização em exemplos práticos, como a COVID-19 e a cirurgia NLPC, para validar o processo.
- Implementar um modelo de rede neural para classificar e priorizar pacientes em uma fila de espera, avaliando sua eficácia.

1.3 JUSTIFICATIVA

A matemática pode ser usada como aliada nos problemas enfrentados por profissionais da área da saúde. Mais especificamente, a priorização de pacientes é uma abordagem que pode auxiliar diversos processos em ambientes hospitalares, além de beneficiar os pacientes. Nesse contexto, cenários de superlotação e falta de recursos em hospitais podem deixar sem cuidados ou atrasar o tratamento de pacientes que realmente necessitem. Em muitos casos, profissionais da saúde precisam tomar decisões difíceis, como por exemplo qual paciente deve ser atendido em detrimento de outros. A priorização de pacientes pode apoiar esse tipo de tomada de decisão por parte de um ser humano, sendo realizada por métodos matemáticos que utilizam da experiência de profissionais atuantes na área em questão. Para isso, será usada uma abordagem do método Fuzzy AHP e redes neurais para priorizar pacientes que estejam em alguma fila de espera. O AHP cria uma estrutura hierárquica dos critérios de decisão do problema e facilita a comparação desses critérios. Além disso, ao final do processo é possível desenvolver um escore quantitativo e ordenado dos pacientes, o que torna coerente o uso do AHP, pois é um método compensatório que leva em consideração os pesos dos critérios. Por outro lado, o AHP apresenta uma dificuldade na coleta de dados dos especialistas pela escala de Saaty, por isso foram utilizados estados linguísticos fuzzy para tratar do problema da subjetividade das respostas dos especialistas. Do mesmo modo, as redes neurais estão sendo amplamente usadas para resolver problemas de saúde e possuem um grande potencial para facilitar processos dentro do hospital, beneficiando pacientes e equipes de saúde com métodos eficientes.

1.4 LIMITAÇÕES DO TRABALHO

Este trabalho apresenta um processo de priorização, que pode ser aplicado a qualquer outro problema de priorização em saúde, sendo ilustrado por dois exemplos específicos. Na primeira etapa do processo de priorização, o problema utilizado foi referente ao COVID-19 e as demais etapas pelo problema da cirurgia de NLPC. Isso ocorreu por conta da interrupção dos estudos sobre o problema do COVID-19. Em trabalhos futuros seria importante exemplificar o processo com um único problema, desde o início até o final do processo, para que haja uma continuidade no entendimento do processo de priorização.

1.5 ESTRUTURA DO TRABALHO

O segundo capítulo deste trabalho apresenta o referencial teórico sobre o tema, buscando na literatura trabalhos sobre priorização de pacientes resolvidos pelo método AHP e por métodos de Inteligência Artificial, apontando quais os problemas resolvidos, o método de resolução e os resultados de cada trabalho encontrado. Os capítulos três e quatro apresentam a base conceitual do trabalho. Desta forma, o terceiro capítulo aborda os conceitos e o passo a passo do método Fuzzy AHP utilizado. O quarto capítulo apresenta os conceitos e o processo de resolução de uma rede neural. O quinto capítulo apresenta a estrutura do processo de priorização, detalhando a metodologia utilizada nesta pesquisa. Ele descreve como os critérios foram elencados, como foi realizada a priorização dos critérios e dos pacientes e como foi estruturada a abordagem de redes neurais. O sexto capítulo se trata da exemplificação do processo de priorização, utilizando os dois problemas. O sétimo capítulo apresenta a abordagem de redes neurais para o problema de NLPC. O oitavo capítulo traz os resultados da priorização de pacientes e da abordagem de redes neurais. Por fim, o nono capítulo apresenta as considerações finais do trabalho.

2 REFERENCIAL TEÓRICO

A metodologia multicritério de apoio a decisão está cada vez mais sendo utilizada na área da saúde, apoiando as tomadas de decisão e facilitando os serviços de saúde (CITRAWATI et al. 2020; FRAZÃO et al., 2018; THOKALA et al., 2016). Jiang et al. (2017) mencionam que métodos de inteligência artificial também ganharam grande espaço na saúde, podendo auxiliar equipes médicas nos julgamentos humanos, inclusive a substituição desse julgamento, quando necessário. Os autores também enfatizam que as técnicas de IA podem identificar informações mais facilmente, no meio de uma grande quantidade de dados, auxiliando as tomadas de decisão. Uma das difíceis decisões a serem tomadas em ambientes da área de saúde é decidir qual paciente deve receber prioridade no atendimento. Isso pode ser resolvido utilizando métodos de análise de decisão e de inteligência artificial, buscando uma maneira eficiente e justa de priorizar esses pacientes.

Karalliedde et al. (2023) desenvolveram uma estrutura de critérios baseados em dados para auxiliar na priorização de pacientes com diabetes no atendimento ambulatorial. Segundo os autores, esses procedimentos foram atrasados durante a pandemia do COVID-19 e as complicações poderiam ser retardadas ou prevenidas se houvesse um atendimento e cuidado de forma rápida e eficaz. Dessa forma, o objetivo dos autores era identificar e priorizar o atendimento dos pacientes com maior probabilidade de piora clínica. Para realizar a priorização, os autores avaliaram critérios de risco em diabetes proposto por uma organização que trata dos riscos em diabetes e discutiram esses critérios em um grupo de 10 especialistas, para obter um consenso sobre quais critérios fariam parte do estudo. Esses especialistas selecionaram uma lista de critérios, os quais foram criptografados e transferidos para servidores. Os pacientes receberam uma pontuação e foram classificados nos grupos: alto risco (um ou mais critérios preocupantes), menor risco (nenhum critério preocupante e um ou mais critérios encorajadores), risco moderado (nenhum critério preocupante ou encorajador e um ou mais critérios ambíguos) e risco desconhecido (nenhum dado novo desde a última consulta liderada pelo consultor). Além disso, os autores validaram o modelo comparando a resposta resultante desse processo com a opinião médica. Os resultados mostraram que 13,6% dos pacientes estavam categorizados como alto risco, 2,5% como ambíguos, 72,5% não tinham novos dados desde a última revisão clínica e 11,4% como menor risco. Dessa forma, o estudo

demonstrou a aplicabilidade e a validade do sistema utilizado, podendo identificar as pessoas com maior necessidade de atendimento e a possibilidade de redução dos atrasos no cuidado com esses pacientes.

Oliveira et al. (2020) propuseram uma abordagem de priorização e agendamento de pacientes numa sala de cirurgia. Os pacientes numa lista de espera eletiva, recebiam uma pontuação de utilidade referente a sua necessidade de atendimento em relação aos outros pacientes. Os autores elaboraram um modelo matemático de programação linear inteira que maximizava a utilidade total e os outros critérios. Os autores verificaram também se a função objetivo deteriora a quantidade de cirurgias programadas e se o tempo de espera dos pacientes é afetado. O modelo foi motivado pelo estudo de um Departamento de Urologia no Canadá, mas pode ser adaptado a outros problemas. Para realizar experimentos computacionais, os autores utilizaram instancias geradas automaticamente, as quais apresentavam dados sobre os pacientes, os tipos e parâmetros da cirurgia, os cirurgiões e a capacidade do sistema do Departamento de Urologia de um Hospital Universitário na cidade de Quebec, Canadá. Os resultados do experimento mostraram que a função objetivo não deteriora a eficiência dos agendamentos, com relação ao número de cirurgia programadas, há mais pacientes de alta pontuação de utilidade agendados para a cirurgia e os tempos de espera foram menores do que dos pacientes de baixa pontuação de utilidade. Mas, os tempos dos pacientes de baixa pontuação foram muito longos e até inaceitáveis. Por isso, os autores propuseram uma abordagem de pontuação de utilidade dinâmica, a qual aumenta a utilidade dos pacientes de acordo com o seu tempo na lista de espera.

Rahimi et al. (2020) desenvolveram uma ferramenta de priorização para priorizar pacientes para um serviço de reabilitação para doenças crônicas. Os autores solicitaram que pacientes, cuidadores e prestadores de serviço identificassem os critérios para a priorização, depois chegassem a um consenso sobre os critérios mais importantes e identificassem pesos para esses critérios. Os autores realizaram duas fases para desenvolver a ferramenta uma fase para obter os critérios e outra para determinar o peso desses critérios. Na primeira fase realizaram entrevistas por telefone com pacientes, cuidadores e prestadores de serviço para identificar os critérios e após, uma reunião com os membros da equipe que atendem os pacientes para entrar num consenso sobre os principais critérios, usando uma análise temática indutiva. Os pacientes não participaram da reunião de consenso devido suas

condições de saúde. Na segunda fase os autores realizaram a determinação dos pesos dos critérios com o método AHP baseado em Fuzzy. Para isso, eles enviaram aos participantes por e-mail um questionário com perguntas sobre os critérios par a par, ou seja, os participantes deveriam avaliar a importância de cada critério em relação aos outros. Para analisar as respostas dos questionários, os autores criaram uma matriz de comparação par a par e em seguida utilizaram procedimentos de álgebra matricial, para criar escalas que indicam o peso relativo de cada critério. Com a primeira fase, nas entrevistas, foram mencionados 40 critérios e após a reunião para obter um consenso foram selecionados 8 critérios. Na segunda fase os critérios foram pontuados em ordem de prioridade. Os critérios na ordem do mais prioritário ao menos prioritário são: segurança da pessoa, potencial de desenvolvimento de riscos, bem-estar psicológico, bem-estar físico, prognóstico de vida, possível impacto no ambiente social, relações interpessoais e responsabilidades e papel social. Os autores acreditam que essa nova ferramenta pode apresentar impactos significativos no sistema de reabilitação melhorando as políticas existentes e o atendimento ao público.

Rahimi et al. (2015) desenvolveram uma estrutura de priorização para o acesso aos serviços de saúde. Os autores mencionaram que permanecer em listas de espera por muito tempo pode causar muitos danos a pacientes, os quais poderiam ser evitados se tivessem um atendimento mais rápido. Dessa forma, os autores propuseram essa estrutura interdisciplinar, sistemática e inovadora, considerando incertezas, diferentes critérios e riscos. Para isso, os autores utilizaram o conceito de conjuntos soft fuzzy para priorizar pacientes. Dessa forma, o Processo Analítico de Rede (ANP) foi usado para encontrar os pesos dos critérios e dos riscos e uma abordagem baseada na noção de conjunto soft fuzzy para priorizar os pacientes. Os autores realizaram um experimento numérico hipotético, considerando quatro pacientes, três critérios e três riscos (risco de morte, risco de comorbidade e risco de infecção). Os pesos obtidos para os critérios e os riscos utilizando o ANP foram: (C1= 0,08, C2= 0,68, C3= 0,24), (R1= 0,79, R2= 0,15, R3= 0,06). A ordem de prioridade dos pacientes foi: P2= 47,8, P3= 38,1, P1= 33,5 e P4= 20,8. Para verificar a robustez da proposta, os autores variaram os pesos do critério principal (C2) e do risco principal (R1) e observaram a posição dos pacientes. Com essa análise de sensibilidade os autores verificaram que a estrutura proposta é robusta nos oito cenários que propuseram. Os autores compararam o método proposto por eles com outros quatro métodos de Análise de Decisão Multi-critério (AHP, ANP, TOPSIS e DEA), mostrando

as vantagens do método abordado nesse trabalho, como considerar os riscos e a incerteza. Por fim, os autores mencionam que esse trabalho oferece uma priorização mais precisa e confiável para os pacientes, no lugar de uma simples ordenação e tem também a capacidade de ser adaptado a outros problemas, sendo possível também a elaboração de um software de fácil utilização.

Nesta seção serão apresentados trabalhos que tratam sobre a priorização de pacientes na área da saúde. A pesquisa na literatura foi dividida em duas partes, na primeira parte trabalhos que utilizaram o método AHP e na segunda parte trabalhos que utilizaram métodos de Inteligência Artificial. Nas duas etapas a busca foi realizada nas bases de pesquisa “*Web of Science*” e “*Scopus*”.

2.1 PROCESSO HIERÁRQUICO ANALÍTICO – AHP

2.1.1 Busca na Web of Science

A busca foi realizada pelas palavras “*Priorit**” and “*Analytic Hierarchy Process*” and “*HealthCare*”, como apresentado abaixo:

((ALL=(*priorit**)) AND ALL = (*analytic hierarchy process*)) AND ALL = (*healthcare*)

Foram encontrados 102 artigos e após a leitura dos títulos foram selecionados 15 artigos. Os outros foram descartados, pois não eram referentes ao tema em questão. Os 15 artigos foram analisados mais profundamente e dentre eles, foram selecionados 7 artigos. Os outros artigos foram descartados pois não tratavam especificamente da priorização de pacientes utilizando o método AHP. Após uma atualização no ano de 2024, foi encontrado mais um artigo, totalizando 8 artigos.

2.1.2 Busca na Scopus

A busca foi realizada pelas palavras “*Priorit**” and “*Analytic Hierarchy Process*” and “*HealthCare*”, como apresentado abaixo:

(TITLE-ABS-KEY (*priorit**) AND TITLE-ABS-KEY (*analytic AND hierarchy AND process*)) AND TITLE-ABS-KEY (*healthcare*)).

Foram encontrados 110 artigos e após isso, foi feita uma leitura dos títulos e 18 foram escolhidos para uma leitura mais aprofundada. Dentre esses, restaram 7 artigos, pois os outros não estavam de acordo com o tema deste trabalho. Mas, dentre esses 7 artigos, 5 eram os mesmos que foram escolhidos na base de dados *Web of Science*. Desta forma, considerando as duas bases de pesquisa, 10 artigos compõem essa etapa do referencial teórico que estão descritos na próxima subseção.

2.1.3 AHP na Priorização de Pacientes em *Healthcare*

Os Métodos Multicritério de Apoio à decisão (MMAD) surgem como um auxílio na tomada de decisão, tendo uma ampla aplicação na área da saúde (FRAZÃO et al., 2018). As abordagens multicritério podem ser ferramentas poderosas na melhoria da saúde do paciente e na alocação de recursos no ambiente hospitalar (TANIOS et al., 2013). Segundo Citrawati et al. (2020), o método AHP pode identificar causadores de problemas de saúde para que a equipe médica possa propor soluções de maneira mais adequada e rápida, facilitando os serviços de saúde. Os dez artigos selecionados para essa revisão utilizam o método AHP para resolver problemas de priorização de pacientes, os quais abordaram temas sobre a COVID-19, doenças cardíacas, problemas gastrointestinais, quedas de idosos, resgates de pessoas presas devido a acidentes, exame urológico e cirurgia ortopédica considerando incertezas. Estes trabalhos estão descritos na sequência e no QUADRO 1 são apresentados resumidamente o autor e ano do trabalho, o problema abordado, o método de resolução do problema e os resultados obtidos.

Özkan et al. (2021) propuseram uma abordagem baseada na tomada de decisão multicritério visando priorizar pacientes com COVID-19 para admissão na UTI, devido as condições de escassez de recursos causadas pela pandemia do novo coronavírus. Os autores determinaram os critérios e sua hierarquia para admissão na UTI apoiados na literatura e na decisão de um conjunto de médicos. Para determinar a priorização dos critérios utilizaram o método Fuzzy AHP com os pesos propostos pelos especialistas, levando em consideração a incerteza da escolha desses pesos. Em seguida, utilizaram o método MOORA (Otimização Multi-Objetivo com base na Análise de Razão) para determinar qual paciente teria mais necessidade de ocupar a UTI. Na etapa de priorização dos critérios, a “pontuação do SOFA” foi o mais

dominante, o “aumento das enzimas cardíacas (troponina)” foi o segundo mais dominante e o terceiro foi a “saturação de oxigênio”. O critério menos dominante segundo o método Fuzzy AHP foi o “distúrbios de perfusão da pele”. No estágio da escolha dos pacientes, além de obterem uma escala da ordem de escolha dos pacientes, os autores analisaram alguns cenários onde foram mudados os pesos dos critérios e utilizadas as abordagens de multicritério EDAS (Avaliação baseada na Distância da Solução Média) e TOPSIS (Técnica para Ordenação por Similaridade com a Solução Ideal) para o ranking de pacientes. Com os cenários, os autores constataram quem a variabilidade no peso dos critérios afeta o ranking de pacientes, sendo que alguns pacientes apresentaram menores variabilidades do que os outros, mostrando então que a robustez da classificação é mais alta em alguns pacientes. Esses métodos, quando comparados com o método MOORA apresentaram 50% de diferença e segundo os médicos participantes do trabalho, o método MOORA apresentou resultados mais razoáveis.

O estudo de Hamid et al. (2021) visou realizar uma triagem de pacientes com doenças cardíacas que se encontravam em um sistema de saúde domiciliar. A triagem foi feita por meio de uma classificação e depois uma priorização desses pacientes utilizando dados de monitoramento remoto de seus sinais vitais para que pudessem receber serviços de emergência e de tratamento. O processo de classificação categorizou os pacientes em cinco grupos, alto risco, requer atendimento de urgência, doente, resfriado (*cold state*) e normal. Após essa classificação os pacientes foram priorizados em cada categoria, de acordo com o status de emergência, depois foram colocados numa fila. Para a classificação, os autores utilizaram um método baseado na teoria de *Dempster-Shafer* e para a priorização modelos híbridos MLAHP (Processo Analítico Hierárquico em Múltiplas Camadas) e TOPSIS. O modelo de MLAHP foi utilizado para obter os pesos, com base no julgamento de seis especialistas, para os quatro critérios primários de sensor de SpO₂, sensor de Batimentos Cardíacos – ECG, sensor de Pressão Arterial - BP e entradas de textos referentes a dor no peito, falta de ar, palpitação e a condição física de repouso ou exercício. O modelo TOPSIS foi utilizado para priorizar e classificar os pacientes, de acordo com os pesos obtidos. A abordagem proposta pelos autores foi validada por meio de um software estatístico, avaliada para determinar o seu desempenho e comparada com as estruturas mais relevantes na área do presente estudo. De acordo com o resultado obtido pelos autores, a abordagem proposta mostrou vantagens de

33,33% e 50% sobre outras estruturas de classificação e de 50% sobre uma estrutura de priorização. Desta forma, a estrutura foi apresentada como uma boa opção para aumentar o desempenho de classificação e priorização em telemedicina.

Hezam et al. (2021) apresentaram uma proposta para distribuição de vacinas para o Covid-19 devido as circunstâncias de pandemia em que o mundo está inserido e supondo que haja desafios de fornecimento, armazenamento e entrega das vacinas. Desta forma, os autores tinham como objetivo priorizar grupos de indivíduos para alocação da vacina do COVID-19 por meio de uma abordagem neutrosófica de multicritério. Os autores identificaram quatro critérios principais baseados em idade, estado de saúde, estado da mulher e tipo de trabalho e, dentre eles, quinze subcritérios. Esses critérios foram escolhidos segundo alguns relatórios da Organização Mundial de Saúde e segundo a opinião de alguns especialistas. Após isso, os autores utilizaram o método AHP neutrosófico para determinar o peso dos critérios, obtendo maior flexibilidade ao estudo e o método TOPSIS para avaliar as alternativas de vacinas mais adequadas para cada grupo. Devido à falta de informação sobre as vacinas, os autores fizeram suposições para que o estudo pudesse ser realizado. Supuseram que seis vacinas foram aprovadas pela OMS e que cada uma delas era mais adequada para determinado grupo. Os autores obtiveram como resultado critérios mais importantes dentre os critérios principais e dentro de cada grupo de critérios principais. No geral, as pessoas com estado de saúde grave possuem prioridade de tomar a vacina, independente dos outros critérios. Depois, as pessoas idosas possuem prioridade, seguido por pacientes infantis e adultos. As mulheres grávidas tem maior prioridade do que lactantes e os profissionais de saúde são prioritários em comparação com os trabalhadores essenciais. Considerando pessoas saudáveis, os idosos tem prioridade, depois crianças e adultos, nessa ordem. A vacina prioritária foi a mais adequada para pessoas com problemas de saúde grave e em seguida, a mais adequada para profissionais de saúde, depois para idosos, para mulheres grávidas/lactantes e em último lugar para crianças e jovens.

Albahri et al. (2020) realizaram uma priorização de pacientes com COVID-19 propondo uma nova estrutura de exames laboratoriais multi-biológicos, para verificar a necessidade de cuidados imediatos para determinados pacientes, enquanto outros podem esperar com segurança o atendimento. O estudo foi realizado com base na análise de dados reais de pacientes que testaram positivo para o COVID-19. Dentre seis pacientes, um estava assintomático, apresentando alteração somente no nível de

proteína C reativa, enquanto ou outros apresentaram anormalidades nos exames. A metodologia proposta pelos autores foi dividida em três partes, identificação, definição de pesos para os critérios e a priorização dos pacientes com COVID-19. Na fase da identificação, o conjunto de dados dos pacientes é pré-processado, depois as informações são analisadas e utilizadas para propor a matriz de decisão que era composta pelos “critérios de exames laboratoriais biológicos” e pela “lista de pacientes que foram infectados pelo COVID-19”. Na segunda fase, os pesos dos critérios foram determinados utilizando o método AHP e na terceira fase, o método de classificação de Compromisso Multicritério - VIKOR foi utilizado para priorizar os pacientes. Dois especialistas foram responsáveis pela atribuição de pesos na abordagem proposta. Os critérios CRP, mg/L, Eosinófilos, $\times 10^9 / L$ e Razões de eosinófilos foram colocadas na prioridade máxima, podendo afetar a classificação do paciente de 9% a 18%. Em relação aos pacientes, o paciente número 1, que era um portador assintomático da doença, ficou em último lugar na priorização e os pacientes de números 5 e 6 ficaram em nível de risco, cada um recebeu o valor máximo de um dos especialistas e seus exames laboratoriais diferiam ligeiramente, mas essa diferença foi resolvida pelo método VIKOR e o paciente 6 ficou na primeira posição da priorização.

Mühlbacher e Kaczynski (2016) realizaram um estudo que buscava identificar e documentar os critérios mais relevantes para terapia com medicamentos de problemas gastrointestinais, levando em consideração a opinião de pacientes e de especialistas da área. Para este fim, os autores fizeram uma revisão da literatura, para coleta de dados sobre aspectos do tratamento do ponto de vista do paciente e com base em estudos clínicos. Nesta pesquisa, os autores selecionaram 23 atributos de terapia e realizaram entrevistas qualitativas com 6 pacientes que receberam tratamento ambulatorial ou hospitalar devido a problemas gastrointestinais. A próxima etapa foi o desenvolvimento de um questionário pré-teste para a pesquisa quantitativa com um aprimoramento após entrevistas com 4 especialistas. Após isso, o questionário final foi aplicado a 20 especialistas de um congresso de gastroenterologia e os autores aplicaram os métodos AHP e escala *Best-Worst*, também com o objetivo de avaliar e comparar os métodos. A análise de literatura e entrevistas resultou em 23 critérios e 7 critérios mais importantes pelos pacientes, os quais foram utilizados na pesquisa quantitativa. Na pesquisa dos especialistas, os 7 critérios foram avaliados pelos especialistas e um resumo final foi estabelecido, com 7 critérios e dois subcritérios para cada um e foram incluídos no questionário final. No AHP os principais

critérios foram redução das cólicas abdominais, redução da dor epigástrica e tempo de início de ação e em último lugar ficou a redução do risco de cefaléia. O método *Best-Worst* escala foi realizado com uma das sessões do questionário avaliando 10 sintomas gastrointestinais e os sintomas mais importantes foram vômito, cólicas abdominais e dor epigástrica e os sintomas que causam menos impacto foram sensação de saciedade, perda de apetite e saciedade precoce. Na discussão sobre a aplicabilidade do AHP os autores ressaltaram que o método é adequado embora tenha limitações metodológicas para os pesos dos critérios. No geral, os dois métodos apresentaram uma abordagem adequada e transparente, o AHP pôde informar os aspectos mais importantes no tratamento com medicamentos e o *Best-Worst* apresentou os sintomas que causavam maior ou menor impacto negativo no bem-estar do paciente. Desta forma, os autores destacam “cólicas abdominais” e “dor epigástrica” como os critérios mais relevantes de acordo com os métodos utilizados e com a opinião de pacientes e especialistas.

O assunto do estudo de Pecchia et al. (2011) foi sobre a prevenção de quedas de pessoas idosas em suas casas, devido a grande quantidade de quedas de pessoas com idade avançada. Tendo como consequência problemas psicológicos, lesões físicas, interferência no bem-estar, na qualidade de vida e na mobilidade, hospitalização e até a morte. Diante disso, os autores tiveram como objetivo examinar opiniões de especialistas de saúde envolvidos com a prevenção, tratamento e gestão de quedas de idosos para elencar os fatores que levam ao maior risco desse problema. Os autores utilizaram o método AHP por ser um método que busca quantificar o conhecimento qualitativo. Desta forma, o método AHP foi aplicado para desenvolver uma hierarquia de fatores de risco de quedas baseado nas opiniões de especialistas. Os autores realizaram uma revisão da literatura para identificar os fatores de risco, classificar os fatores em categorias de acordo com seus conhecimentos clínicos e elaborar um questionário piloto e após um aprimoramento obtiveram um questionário final para que especialistas pudessem atribuir pesos aos fatores, comparando-os par a par. Após a aplicação do questionário, foi possível construir a matriz de julgamentos de cada categoria. Com isso, os autores puderam analisar e priorizar o conjunto de resposta desse questionário. Com a revisão da literatura, os autores encontraram 39 fatores de risco e após a aplicação do questionário piloto permaneceram 35, os quais foram divididos em duas categorias e três subcategorias em cada categoria. O questionário piloto foi respondido por 9

especialistas e o questionário final utilizou as respostas de 56 especialistas, 12 médicos e 44 fisioterapeutas que responderam ao questionário de forma consistente. Com a aplicação do AHP, a subcategoria que foi avaliada como mais relevante foi a “saúde física” com quase o dobro de relevância do fator “riscos socioambientais”. Três subcategorias ficaram com a porcentagem de importância bem próximas, “drogas”, “físico” e “mental” e por último as subcategorias “médica” e “sócioambiental”. O fator de risco mais importante foi “perda de equilíbrio”, sendo considerada 5,5 vezes mais importante do que “baixo suporte de serviços sociais”, que foi o último fator da lista. Os fatores “sedativos” e “problemas de continência” foram o segundo e o terceiro fatores mais importantes, respectivamente. Desta forma, os autores concluíram que o estudo pode fornecer informações sobre a opinião de especialistas no que diz respeito a queda de idosos e os fatores de risco podem contribuir para futuros programas de prevenção de quedas.

Moulik et al. (2015) apresentaram uma técnica, denominada *Smart-Evac*, para fornecer ajuda em ocasiões de emergências que incluem resgate de pessoas presas. Os autores consideraram três “Vs”, volume, variedade e velocidade de Big Data, tendo em vista formar grupos de pessoas para serem resgatadas com base na concentração da presença física das vítimas. Segundo os autores, os grupos que estão em maior risco, se tiverem acesso a dispositivos em que conseguem se comunicar com o mundo exterior, tendem a enviar o maior número de mensagens e grandes fluxos de dados são enviados para a nuvem, o que pode causar congestionamento da rede com risco de colapso no sistema de comunicação. Desta forma, o AHP é utilizado para classificar os grupos de acordo com os três “Vs”, priorizando os grupos com mais gravidade para o resgate ser realizado, além de realizar uma classificação dentro dos grupos, para o acompanhamento no resgate. Após o resgate, as vítimas são monitoradas fisiologicamente por sensores corporais, para que a equipe médica possa decidir quais dos pacientes necessitam de internamento em hospitais. Os autores consideraram uma situação pós-desastre em que as pessoas ficam presas onde os grupos foram denominados de A até O. Os resultados obtidos mostraram que o grupo G foi o que mais contribuiu para o congestionamento das redes com uma responsabilidade de 9,38%, sendo assim o grupo prioritário para o resgate. Os outros grupos com maiores responsabilidades de congestionamento foram o A e o H com 8,84% e 8,405 respectivamente.

Pécora et al. (2021) descrevem as fases e etapas da identificação e avaliação de critérios relevantes para obter uma priorização de pacientes para o acesso a um exame urológico no Hospital das Clínicas em Curitiba, denominado Estudo Urodinâmico. Segundo os autores há uma grande demanda de pacientes para a realização desse exame e poucas vagas, tendo uma lista de espera de 3000 pacientes e um tempo de espera de 3 anos. Visando ajudar na solução desse problema, foi montada uma equipe multidisciplinar composta por profissionais da saúde, matemáticos, engenheiros e estatísticos. O processo foi realizado em quatro fases, Fase de Planejamento, Construção, Fase de Implementação e Encerramento, tendo sido concluída duas fases até a publicação do artigo. Na fase de planejamento, foram definidos os fundamentos do projeto, os quais são a definição do problema, quem estará envolvido e o que será feito. O problema se trata da fila e tempo de espera dos pacientes para o exame de urologia, os participantes serão pacientes, equipe médica e equipe administrativa e será realizada uma priorização dos pacientes do mais urgentes ao menos urgente. O mapeamento dos critérios foi realizado de acordo com as definições da Sociedade Brasileira de Urologia e com a coordenação de um professor médico urologista. Os critérios principais são: Doença encontrada, Problemas de saúde, Condição social, Qualidade de vida e Exames e cada um desses critérios possui de dois a quatro subcritérios. A fase de construção consiste em duas etapas, a determinação dos pesos para cada critério e coleta de dados dos pacientes. Para a determinação dos pesos dos critérios foi utilizado o método Fuzzy AHP, tendo sido aplicado um questionário para especialistas para compararem a importância dos critérios par a par, comparando cada critério com os demais. Os graus de preferência foram apresentados em quatro estados linguísticos difusos e depois representados por funções triangulares fuzzy. Com a aplicação do método, o critério com maior peso foi Problemas de Saúde (28,81%), depois Exames Complementares (24,90%), Doença (21,45%), Social (8,38%) e os subcritérios com maior peso foram Ultrassonografia (12,49%) e Função Renal (12,41%). Os autores observaram que os critérios clínicos receberam pesos maiores do que os critérios sociais. Na coleta de dados dos pacientes, os autores iniciaram com uma amostra de dados sorteando 322 prontuários dos 3000 existentes, mas conseguiram extrair informações de 86 pacientes. A lista de prioridade dos pacientes foi obtida classificando-os de acordo com a sua pontuação e foi validada com sucesso pelo médico chefe do departamento de urologia, o qual realizou uma análise minuciosa dos resultados, obtendo assim um

algoritmo totalmente funcional para priorizar amostras de pacientes. Em trabalhos futuros, os autores pretendem realizar a implementação de uma ferramenta de priorização, para melhorar a utilização dos recursos de saúde.

Rahimi et al. (2016) realizaram uma revisão de literatura para apontar os métodos de priorização mais utilizados e identificar suas principais desvantagens. Após isso, os autores propuseram uma estrutura de priorização de pacientes em sistemas dinâmicos complexos, considerando a opinião de especialistas e dos pacientes, riscos, incertezas e informações incompletas em relação aos critérios de decisão. A estrutura está dividida em três etapas, as quais são uma proposta para melhorar as desvantagens encontradas na literatura. A primeira se trata da aplicação da técnica de decisão multicritério Fuzzy AHP, que visa estabelecer as metas das partes interessadas, considerando as incertezas com a lógica Fuzzy. Na segunda etapa os pacientes recebem uma pontuação individual com uma abordagem de decisão em grupo, de acordo com a avaliação de cada critério feita por especialistas e uma abordagem *Min-Max regret* para obter uma classificação dos pacientes. Na terceira etapa para o ranking de pacientes ser atualizado periodicamente, os autores utilizaram os fatores dinâmicos *Delay Ratio* e *Risk-criteria score*, considerando que os pacientes podem ter uma evolução dinâmica, e para apoiar visualmente a tomada de decisão, utilizaram uma matriz *Risk-Delay*. Os autores propuseram também, um estudo de caso, para aplicar as ferramentas utilizadas, no Departamento de Cirurgia Ortopédica do Hospital Universitário Shohada, em Tabriz, Irã. Eles realizaram uma comparação, por meio de uma pesquisa eletrônica, do método proposto no estudo de caso com o método utilizado pelo hospital, o qual é baseado em uma regra em que o primeiro a chegar é atendido, com exceção de pacientes urgentes. Segundo os respondentes da pesquisa, a nova estrutura apresenta uma melhoria em todos os aspectos da avaliação, comprovando o seu potencial. Em relação a preferência do cirurgião, a nova estrutura apresentou escores de 18% a 40% melhores que o método utilizado no hospital.

Yazici et al. (2022) apresentaram uma proposta que visa priorizar pessoas para tomar a vacina contra o COVID-19. De acordo com os autores, a pandemia foi um período crítico e como não havia doses suficientes da vacina para toda a população, seria essencial ter um planejamento eficaz e justo para selecionar os indivíduos com prioridade. Dessa forma, os autores utilizaram métodos multicritério de apoio a decisão (MMAD) para lidar com a consideração de vários critérios de

decisão para a priorização. Eles separaram esse trabalho em duas fases, a primeira utilizando o método AHP para calcular o peso dos critérios de decisão e a segunda utilizando o método PROMETHEE para obter o ranking das prioridades dos indivíduos. Na primeira fase, cinco médicos especialistas determinaram sete critérios e com o cálculo do AHP, os critérios prioritários apareceram nessa ordem: Ocupação de risco, doenças crônicas, idade, medicamentos de rotina, exposição a COVID-19, sexo e a região que reside. Para a determinar a prioridade com o método PROMETHEE (Método de Organização de Classificação por Preferência para Avaliações de Enriquecimento), foram determinados 10 candidatos e feita uma matriz de dados desses candidatos, para as alternativas serem avaliadas de acordo com esses dados em relação aos critérios dos especialistas. Essa fase foi realizada em conjunto com a anterior, pois utilizou os pesos obtidos para os critérios. Como um dos resultados, o candidato que recebeu a primeira posição da priorização foi um homem de 45 anos e trabalhador da área de saúde. Esse candidato também possui doença crônica, faz uso de medicação de rotina e mora numa região metropolitana. Com esse trabalho, os autores constataram que é recomendado priorizar indivíduos que considerando riscos ocupacionais e doenças crônicas. Eles consideraram a idade como um fator importante também. Então, ressaltaram a importância de dar atenção a mais de um critério na hora de priorizar os pacientes.

QUADRO 1 - TRABALHOS QUE ABORDARAM PROBLEMAS DE PRIORIZAÇÃO UTILIZANDO O MÉTODO AHP

Autores/ano	Problema Abordado	Método de resolução	Resultados
Özkan et al. (2021)	Priorizar pacientes com COVID-19 para admissão na UTI	<ul style="list-style-type: none"> - Fuzzy AHP com os pesos propostos pelos especialistas, considerando a incerteza da escolha dos pesos; - Método MOORA para determinar qual paciente teria mais necessidade de ocupar a UTI; - Abordagens de multicritério EDAS e TOPSIS para o ranking de pacientes, com cenários em que foram mudados os pesos dos critérios. 	<p>Na utilização do método Fuzzy AHP, a “pontuação do SOFA” foi o mais dominante, o “aumento das enzimas cardíacas (troponina)” foi o segundo mais dominante e o terceiro foi a “saturação de oxigênio”. O critério menos dominante foi o “distúrbios de perfusão da pele”.</p> <p>Com os cenários, a variabilidade no peso dos critérios afetou o ranking de pacientes, mostrando então que a robustez da classificação é mais alta em alguns pacientes. O EDAS e o TOPSIS, quando comparados com o método MOORA apresentaram 50% de diferença e o método MOORA apresentou resultados mais razoáveis.</p>

Hamid et al. (2021)	Triagem de pacientes com doenças cardíacas que se encontravam em um sistema de saúde domiciliar	<ul style="list-style-type: none"> - Para a classificação, foi utilizado um método baseado na teoria de <i>Dempster-Shafer</i>; - Na priorização, foram utilizados modelos híbridos de MLAHP e TOPSIS, o MLAHP foi utilizado para obter os pesos, com base no julgamento de seis especialistas. E o modelo TOPSIS foi utilizado para priorizar e classificar os pacientes, de acordo com os pesos obtidos. 	A abordagem proposta mostrou vantagens de 33,33% e 50% sobre outras estruturas de classificação e de 50% sobre uma estrutura de priorização. Desta forma, a estrutura foi apresentada como uma boa opção para aumentar o desempenho de classificação e priorização em telemedicina.
Hezam et al. (2021)	Priorização de grupos de indivíduos para alocação da vacina do COVID-19	<ul style="list-style-type: none"> - AHP neutrosófico para determinar o peso dos critérios; - TOPSIS para avaliar as alternativas de vacinas mais adequadas para cada grupo. 	A vacina prioritária foi a mais adequada para pessoas com problemas de saúde grave e em seguida, a mais adequada para profissionais de saúde, depois para idosos, para mulheres grávidas/lactantes e em último lugar para crianças e jovens.
Albahri et al. (2020)	Priorização de pacientes com COVID-19 propondo uma nova estrutura de exames laboratoriais multi-biológicos.	<ul style="list-style-type: none"> - o método AHP foi utilizado para determinar os pesos dos critérios; - O método VIKOR foi utilizado para priorizar os pacientes. 	Os critérios CRP, mg/L, Eosinófilos, x10 ⁹ / L e Razões de eosinófilos foram colocados na prioridade máxima, podendo afetar a classificação do paciente de 9% a 18%. Em relação aos pacientes, o paciente número 1, que era um portador assintomático da doença, ficou em último lugar na priorização e os pacientes de números 5 e 6 ficaram em nível de risco, cada um recebeu o valor máximo de um dos especialistas e seus exames laboratoriais diferiam ligeiramente, mas essa diferença foi resolvida pelo método VIKOR e o paciente 6 ficou na primeira posição da priorização.
Mühlbacher; Kaczynski (2016)	Identificação e documentação dos critérios mais relevantes para terapia com medicamentos de problemas gastrointestinais.	<ul style="list-style-type: none"> -AHP; -Escala <i>Best Worst</i>. 	No AHP os principais critérios foram redução das cólicas abdominais, redução da dor epigástrica e tempo de início de ação e em último lugar ficou a redução do risco de cefaléia. No método <i>Best-Worst</i> os sintomas mais importantes foram vômito, cólicas abdominais e dor epigástrica e os sintomas que causam menos impacto foram sensação de saciedade, perda de apetite e saciedade precoce. Os dois métodos apresentaram uma

			abordagem adequada e transparente, o AHP pôde informar os aspectos mais importantes no tratamento com medicamentos e o Best-Worst apresentou os sintomas que causavam maior ou menor impacto negativo no bem-estar do paciente.
Pecchia et al. (2011)	Prevenção, tratamento e gestão de quedas de idosos para elencar os fatores que levam ao maior risco desse problema.	- AHP foi aplicado para desenvolver uma hierarquia de fatores de risco de quedas baseado nas opiniões de especialistas.	A subcategoria mais relevante foi a “saúde física” com quase o dobro de relevância do fator “riscos socioambientais”. Três subcategorias ficaram com a porcentagem de importância bem próximas, “drogas”, “físico” e “mental” e por último as subcategorias “médica” “sócioambiental”. O fator de risco mais importante foi “perda de equilíbrio”, sendo considerada 5,5 vezes mais importante do que “baixo suporte de serviços sociais”, que foi o último fator da lista. Os fatores “sedativos” e “problemas de continência” foram o segundo e o terceiro fatores mais importantes, respectivamente.
Moulik et al. (2015)	Fornecimento de ajuda em ocasiões de emergências que incluem resgate de pessoas presas, priorizando os grupos com mais gravidade para o resgate ser realizado. Além disso, realizar uma classificação dentro dos grupos, para o acompanhamento no resgate.	- o AHP é utilizado para classificar os grupos.	O grupo G foi o que mais contribuiu para o congestionamento das redes com uma responsabilidade de 9,38%, sendo assim o grupo prioritário para o resgate. Os outros grupos com maiores responsabilidades de congestionamento foram o A e o H com 8,84% e 8,405 respectivamente.
Pécora et al. (2021)	Identificação e avaliação de critérios relevantes para obter uma priorização de pacientes para o acesso a um exame urológico.	- Na determinação dos pesos dos critérios foi utilizado o método Fuzzy AHP.	Com a aplicação do método, o critério com maior peso foi Problemas de Saúde (28,81%), depois Exames Complementares (24,90%), Doença (21,45%), Social (8,38%) e os subcritérios com maior peso foram Ultrassonografia (12,49%) e Função Renal (12,41%). A lista de prioridade dos pacientes foi validada com sucesso pelo médico chefe do departamento de urologia, o qual realizou uma análise minuciosa dos resultados, obtendo assim um algoritmo totalmente funcional

			para priorizar amostras de pacientes.
Rahimi et al. (2016)	Apontamento dos métodos de priorização mais utilizados e identificação de suas principais desvantagens. Após isso, propuseram uma estrutura de priorização de pacientes em sistemas dinâmicos complexos, considerando a opinião de especialistas e dos pacientes, riscos, incertezas e informações incompletas em relação aos critérios de decisão. Realizaram também um estudo de caso no Departamento de Cirurgia Ortopédica.	<ul style="list-style-type: none"> - Fuzzy AHP, que visa estabelecer as metas das partes interessadas, considerando as incertezas com a lógica Fuzzy; - Abordagem <i>Min-Max regret</i> para obter uma classificação dos pacientes; - Para o ranking de pacientes ser atualizado periodicamente, os autores utilizaram os fatores dinâmicos <i>Delay Ratio</i> e <i>Risk-criteria score</i>; - Para apoiar visualmente a tomada de decisão, utilizaram uma matriz <i>Risk-Delay</i>. 	A estrutura de priorização proposta apresentou uma melhoria em todos os aspectos da avaliação, comprovando o seu potencial. Em relação a preferência do cirurgião, a estrutura proposta apresentou escores de 18% a 40% melhores que o método utilizado no hospital.
Yazici et al. (2022)	Priorização de pessoas para tomar a vacina contra o COVID-19	<ul style="list-style-type: none"> - AHP para calcular o peso dos critérios de decisão; - Método PROMETHEE para obter o ranking das prioridades dos indivíduos. 	O candidato que recebeu a primeira posição da priorização foi um homem de 45 anos e trabalhador da área de saúde. Esse candidato também possui doença crônica, faz uso de medicação de rotina e mora numa região metropolitana. Com esse trabalho, os autores constataram que é recomendado priorizar indivíduos considerando riscos ocupacionais e doenças crônicas. Eles consideraram a idade como um fator importante também.

FONTE: A autora (2022).

Os dez artigos selecionados nessa revisão tiveram anos de publicação entre 2011-2024, sendo um artigo de 2011, um de 2015, dois de 2016, um de 2020, quatro de 2021 e um de 2024. Dentre os temas abordados, quatro eram sobre a COVID-19, um sobre doença cardíaca, um sobre problemas gastrointestinais, um sobre quedas de idosos, um sobre ocasiões de emergência/resgate, um sobre exame urológico e um sobre cirurgia ortopédica. Nos métodos utilizados, outros métodos além do AHP foram aplicados aos problemas propostos, dentre eles, três utilizaram o Fuzzy AHP, um utilizou o método MOORA, um utilizou o EDAS, três utilizaram o TOPSIS, um utilizou um método baseado na teoria de *Dempster-Shafer*, um utilizou o MLAHP, um

utilizou o AHP neutrosófico, um utilizou o método VIKOR, um utilizou a escala Escala Best Worst, um utilizou a abordagem Min-Max regret, um utilizou *Delay Ratio* e *Risk-criteria score* e um utilizou uma matriz *Risk-Delay*. Desta forma, houve mais artigos publicados em 2021, o tema mais utilizado foi sobre a COVID-19 e os métodos mais utilizados foram o TOPSIS e o Fuzzy AHP.

Dentre esses trabalhos, é interessante notar que a maioria deles são sobre a COVID-19. Sempre houve escassez de recursos, filas para cirurgias, superlotações em hospitais espalhados pelo mundo, principalmente em países subdesenvolvidos, mas esse problema ficou muito evidente no período da pandemia do novo coronavírus. Foi possível confirmar também, que métodos multicritério de apoio a decisão podem ser uma boa saída para esse tipo de problema, inclusive o método AHP o qual é um método que busca quantificar o conhecimento qualitativo, como foi mencionado por Pecchia et al. (2011). Muitas vezes a equipe de saúde não consegue expressar numericamente a importância de um critério em relação a outros, então o método AHP pode ser usado para facilitar o entendimento das prioridades dos critérios.

Outro fato a ser notado dentre os artigos, foi a escolha dos métodos utilizados pelos autores para a escolha dos critérios. Foram utilizadas a opinião de especialistas, com questionários ou entrevistas; revisão na literatura; a busca em documento que regulamenta os critérios do problema determinado; a opinião dos pacientes e até mesmo uma combinação de alguns desses métodos. Estes processos são muito importantes para a escolha dos critérios e futuramente priorizar os pacientes com mais segurança, tendo em vista os processos de triagem e priorização dos pacientes que são realizados nos ambientes hospitalares, sem a utilização de algum tipo de método.

Também é interessante destacar a classificação dos critérios em grupos de gravidade, em pois permite a visualização e atenção aos pacientes que estejam em grupos menos prioritários, contribuindo para o não esquecimento desses pacientes. Pois, em alguns casos, ocorre do paciente não grave se tornar grave ao longo do tempo, então, com esses grupos é possível escolher também, pacientes de grupos menos prioritários periodicamente.

2.2 INTELIGÊNCIA ARTIFICIAL – IA

2.2.1 Busca na Web of Science

A busca foi realizada pelas palavras “*Patient priorit**”, “*Artificial Intelligence*” and “*HealthCare*”, com os refinamentos “acesso aberto” e tipo de documento “*article*”. Foram encontrados 65 artigos e após a leitura dos títulos, 24 artigos foram selecionados. Os outros foram descartados, pois não eram referentes ao tema em questão. Os 24 artigos foram analisados mais profundamente e dentre eles, foram escolhidos 9 artigos. Os outros artigos foram descartados pois não tratavam especificamente da priorização de pacientes utilizando métodos de inteligência artificial. Após a atualização no ano de 2024, foram encontrados mais 5 artigos, totalizando 14 artigos.

2.2.2 Busca na Scopus

A busca foi realizada pelas palavras “*Patient Priorit**”, “*Artificial Intelligence*” and “*HealthCare*”. Foram encontrados 315 artigos, dentre eles 7 escolhidos.

Foram encontrados 315 artigos e após isso, foi feita uma leitura dos títulos e 36 foram escolhidos para uma leitura mais aprofundada. Dentre esses, 7 artigos foram selecionados, pois os outros não estavam de acordo com o tema desde trabalho. Mas, dentre esses 7 artigos, 1 era o mesmo que foi escolhido na base de dados Web of Science. Desta forma, considerando as duas bases de pesquisa, 20 artigos compõem essa etapa do referencial teórico que estão descritos na próxima subseção.

2.2.3 Inteligência Artificial na Priorização de Pacientes em Healthcare

A inteligência artificial pode transformar o atendimento ao paciente e processos administrativos nos serviços de saúde, mas os sistemas de IA não substituirão o trabalho humano e sim pode fazer com que os profissionais da área da saúde se concentrem em habilidades exclusivamente humanas (DAVENPORT;

KALAKOTA 2019). Alugubelli (2016) menciona que embora a Inteligência Artificial necessite de custos para sua implantação, os benefícios superam essas despesas e pode se tornar acessível para todos.

Nesta revisão, foram selecionados vinte trabalhos que abordam métodos de inteligência artificial para resolver problemas de priorização de pacientes e os temas tratados foram previsão de sepse, covid-19, doença renal crônica, insuficiência cardíaca, anemia falciforme e pacientes que esperam transplante de medula óssea. Esses trabalhos são descritos abaixo e no QUADRO 2 são apresentados de maneira resumida o autor e ano de cada trabalho, os temas tratados, o método de resolução e os resultados obtidos.

Shashikumar et al. (2021) propuseram um modelo de *deep learning* preditor de sepse, denominado COMPOSER. Os autores relataram que o modelo poderia prever o início da sepse em um paciente com um intervalo de 4 até 48 horas antes da suspeita clínica, além de alcançar generalidade aprimorada e baixas taxas de alarmes falsos. O funcionamento do COMPOSER foi separado em três módulos, o primeiro dimensiona o valor de uma variável clínica de acordo com o tempo desde a última medição. O segundo módulo se trata de um preditor conforme que avalia a conformidade de uma nova instancia de teste. O terceiro módulo é a rede neural *feedforward* que prediz o risco de sepse. O modelo foi treinado e avaliado em 515.720 pacientes de UTI e de departamentos de emergência, em dois hospitais (A e B) universitários nos Estados Unidos. A avaliação de desempenho foi realizada utilizando a área sob a curva e o valor preditivo positivo e negativo. Num conjunto de teste interno, o desempenho do COMPOSER na UTI foi de 0,953 de área sob a curva e de 38% no valor preditivo positivo e nos departamentos de emergência, 0,945 de área sob a curva e 20,1% no valor preditivo positivo, mantendo baixas taxas de alarme falso. Neste mesmo conjunto de teste, algumas das variáveis clínicas foram relacionadas como principais fatores que contribuem para a sepse, dentre elas está temperatura, contagem de glóbulos brancos e frequência cardíaca. Realizando uma validação externa comparando com um modelo de rede neural *feedforward*, na UTI do hospital B o COMPOSER apresentou aproximadamente 85,5% de redução em relação a alarmes falsos e 0,925 vs 0,910 da área sob a curva e de 24,3% vs 23% do valor preditivo positivo, comparando o COMPOSER com outro modelo, respectivamente. No Departamento de Emergência do hospital B a redução de alarme falso foi de 77,9%, a área sob a curva 0,938 vs 0,910 e o valor preditivo positivo 13,4%

vs 13,0%. Os autores também realizaram uma validação temporal na UTI e no departamento de emergência do hospital A, com uma rede treinada entre janeiro de 2016 a março de 2019 e aplicado de agosto de 2019 a fevereiro de 2020. O modelo obteve uma área sob a curva de 0,940 no departamento de emergência e 0,952 na UTI, mantendo baixa a taxa de alarme falso, que foi de 0,047 no departamento de emergência e de 0,029 na UTI. Isto sugere que o modelo não foi afetado por mudanças no decorrer desse período. Também na validação temporal, ao ser comparado com um modelo de predição de sepse do hospital A, o modelo reduziu aproximadamente 78% de alarmes falsos, no mesmo período, e obteve uma melhoria significativa no tempo do alarme da notificação da sepse em relação ao modelo do hospital.

O trabalho de Goncharov et al. (2020) visa identificar pacientes com Covid-19 por meio da análise de exames de tomografia computadorizada de tórax e quantificar a gravidade da doença em cada paciente, de maneira a encaminhar os pacientes graves para o devido atendimento. Segundo os autores, a tomografia computadorizada é útil no diagnóstico e triagem da doença, pode apresentar maior sensibilidade em algumas coortes, além de ser de fácil acesso e de apresentar resultados mais rápidos do que testes moleculares. A identificação do Covid-19 na tomografia foi realizada de maneira binária, Covid-19 versus outros estudos e a quantificação. O método utilizado pelos autores iniciou com um pré-processamento realizando uma segmentação dos pulmões em duas etapas, primeiro uma máscara binária única para ambos os pulmões, utilizando uma rede neural totalmente convolucional e depois com máscaras separadas dos pulmões esquerdo e direito realizando um agrupamento com o algoritmo k-means. A próxima etapa do método consistiu em quantificar a gravidade da doença utilizando métodos baseados em limiarização que preveem lesões causadas nos pulmões por consequência do COVID-19. A terceira etapa se trata da identificação da doença em que uma das tarefas utiliza resultados da segmentação para identificar os pacientes com determinadas lesões como pacientes portadores da doença. A segunda tarefa utiliza uma rede neural para classificar os pacientes como positivos ou negativos para a doença. Porém, esses métodos não se mostraram eficazes para a identificação, pois apresenta muitos alarmes falsos em pacientes com pneumonia bacteriana. Na quarta etapa os autores propuseram uma abordagem que resolve a tarefa de identificação e de segmentação simultaneamente, utilizando uma rede neural convolucional de duas cabeças. Com

este método foi possível melhorar os resultados dos alarmes falsos em pacientes com pneumonia bacteriana. Na quinta e última etapa, os autores formalizaram a comparação dos métodos utilizando a área sob a curva (AUC) que qualificaram a identificação e a quantificação de gravidade. Além disso, o coeficiente de correlação de Spearman foi utilizado como uma métrica de qualidade e o coeficiente de pontuação de Dice para avaliar a qualidade da segmentação. Os experimentos realizados compararam os modelos descritos e todos os métodos foram treinados utilizando os mesmos conjuntos de dados e avaliados com as mesmas métricas. Os resultados dos experimentos mostraram que os modelos baseados em segmentação apresentaram um desempenho baixo ao classificar Covid-19 e pneumonia bacteriana. A classificação da doença utilizando rede neural apresentou resultados de área sob a curva altos, porém instáveis. Por fim, o modelo multitarefas superou o modelo anterior em relação a identificação, além de obter mais estabilidade. Este modelo também distingue com mais precisão o Covid-19 das outras doenças pulmonares. Desta forma, este trabalho mostrou que o modelo multitarefas é útil para a identificação e para a classificação do Covid-19.

Wang et al. (2021) realizaram um estudo combinando *deep learning* e radiômica para investigar resultados ruins da Covid-19 em pacientes que já apresentavam condições de saúde subjacentes. Os pacientes que foram incluídos no estudo tinham pneumonia por COVID-19, uma ou mais condições de saúde subjacentes, tomografia computadorizada de tórax sem contraste inicial disponível e um resultado primário (morto, alta ou hospitalizado). Desta forma, participaram da pesquisa 400 pacientes de 4 centros entre janeiro de 2020 e março de 2020. Inicialmente, todos os pacientes realizaram a Tomografia Computadorizada e com os resultados foram realizadas segmentações e pré-processamento do volume do pulmão. Após isso, um modelo de *deep learning* e um modelo de radiômica foram desenvolvidos, ambos para prever a probabilidade de obter resultados ruins. Os autores reuniram as probabilidades dos dois modelos por meio de uma regressão logística multivariada formando um modelo híbrido. Para realizar uma comparação e investigar a vantagem da utilização de imagens, os autores também construíram um modelo clínico sem imagens, com características relatadas pelos pacientes. Os modelos foram avaliados em relação a Área sob a curva (AUC), *Gradient-weighted Class Activation Mapping* (Grad-CAM) e descrições dos recursos de radiômica embutidos no modelo de radiômica. A análise estatística do modelo foi feita com a

validação cruzada 5-fold para avaliar a eficácia e a robustez do modelo, os testes U de Mann-Whitney, Qui-quadrado e teste exato de Fisher para medir as diferenças estatísticas e os testes de log-rank e *Gehan Breslow-Wilcoxon* para comparar as curvas de sobrevida. A média de idade dos pacientes foi de 63,8 anos, as condições de saúde subjacentes mais comuns foram hipertensão (62,5%), diabetes (22%) e doença coronariana (10,5%). A porcentagem de pacientes que apresentaram mais de uma condição de saúde subjacentes foi de 36,8%. O modelo de deep learning apresentou o valor de 0,759 de AUC na identificação de resultados ruins. O modelo de randômica obteve 0,872 e 0,855 de AUC nos conjuntos de treinamento e teste respectivamente. Os resultados também mostraram que os modelos que utilizaram imagens, como os modelos *deep learning*, radiômico e híbrido, apresentaram maior desempenho em comparação com o modelo sem imagens. O modelo híbrido superou os outros modelos, com AUC de 0,876, além de apresentar maior desempenho, robustez e grande capacidade de estratificação de risco. E o modelo híbrido de recursos obteve AUC de 0,786. Além disso, as curvas de sobrevida mostraram que pacientes com COVID-19 com várias condições de saúde subjacentes apresentaram maior risco de morte. Desta forma, o modelo híbrido se mostrou uma boa ferramenta na identificação de resultados ruins apresentados por pacientes com COVID-19 que apresentam condições de saúde subjacentes.

O trabalho de Quiroz et al. (2021) apresentou uma previsão da gravidade da COVID-19 utilizando dados clínicos e de imagens de pacientes que testaram positivo para a doença. Tendo em vista que a identificação de casos mais graves da doença pode evitar a sobrecarga dos leitos e recursos de saúde e ter a possibilidade de não atrasar o tratamento da doença. A gravidade da doença foi separada em quatro categorias, leve, comum, grave e crítica. Para realizar a previsão, os autores utilizaram dados de 346 pacientes de dois hospitais que realizaram uma tomografia computadorizada de tórax no início da internação. Nessas tomografias, os autores realizaram o pré-processamento e após realizaram a segmentação pulmonar usando um modelo denominado de 'R231CovidWeb' que foi treinado utilizando uma grande quantidade de dados que apresentavam TC de tórax sem COVID-19. Para prever a gravidade da doença os autores utilizaram três modelos, uma regressão linear (com *scikit-learn*), um gradiente *boosted trees* (*XGBoost*) e uma rede neural (*fast.ai*). Como a maioria dos casos obtidos apresentou gravidade leve/comum, os autores testaram quatro métodos de sobreamostragem para aumentar a proporção a classe minoritária.

Os métodos foram *synthetic minority oversampling (SMOTE)*, *Adaptive Synthetic Sampling, geometric (ADASYN)* e um modelo *conditional generative adversarial network (CTGAN)* para dados tabulares. Para avaliar as diferenças entre os grupos de gravidade da doença os autores utilizaram o teste U de Mann-Whitney e o teste exato de Fisher. Os resultados mostraram que a idade média dos pacientes dos grupos leve/comum foi de 48,5 anos e dos pacientes do grupo grave/crítico foi de 63 anos. Em relação as comorbidades, doença cardiovascular, hipertensão, diabetes e câncer foram mais encontradas nos pacientes dos grupos grave/crítico. E em relação aos sintomas, aumento da frequência respiratória e dispneia foram mais comuns nos grupos grave/crítico. O modelo considerou características demográficas e sintomas dos pacientes, características clínicas, características de imagem e uma combinação de características clínicas e de imagem. O modelo de regressão linear obteve maior desempenho e os resultados de imagem apresentaram melhores do que os recursos clínicos e a combinação de imagem e recursos clínicos favoreceu somente o modelo regressão linear. A sobreamostragem SMOTE melhorou o desempenho do modelo e os resultados mostraram que o aumento nas características de imagem volume de consolidação, volume total da lesão, volume em vidro fosco e volume de outras anormalidades tem maior probabilidade de prever caso grave/crítico. Outras características que apareceram como maior probabilidade de ocorrer caso grave/crítico foram baixos níveis de albumina, altos níveis de proteína C reativa, alta contagem de leucócitos e baixos níveis de lactato desidrogenase. Ainda, a idade avançada e o sexo masculino também contribuíram para previsão desses resultados graves/críticos. Com isso, os autores mostraram que os recursos clínicos e de imagem facilitam o diagnóstico do paciente com COVID-19, considerando também que os método e modelos propostos são totalmente automatizados, o que agiliza o atendimento e o tratamento de pacientes com potencial a ter doença grave/crítica em hospitais sobrecarregados pelo surto da doença.

Meng et al. (2020) desenvolveram um modelo de *deep learning* para prever o risco de morte de pacientes com COVID-19, de forma não invasiva, considerando resultados de tomografia computadorizada (TC) e informações clínicas. Como descrito pelos autores, a TC foi considerada um método alternativo para detectar a COVID-19, levando em consideração o alto índice de resultados falsos negativos e a falta de kits do teste de Reação em Cadeia da Polimerase de Transcrição Reversa (RT-PCR). Porém, muitos tipos de pneumonia viral apresentam resultados semelhantes nas

tomografias computadorizadas e não podem ser identificados por radiologistas. Considerando isto e que a doença tem um processo de deterioração rápido, apresentar soluções para detectar pacientes de alto risco é urgente. Assim, os autores desenvolveram uma rede neural convolucional 3D (3D-CNN) denominada De-COVID19-Net que prevê a probabilidade de morte dos pacientes em duas semanas. Eles recrutaram 366 participantes, de quatro hospitais diferentes, que apresentavam pneumonia por COVID-19 confirmada por testes RT-PCR, foram diagnosticados com pneumonia grave ou crítica de acordo com o protocolo de diagnóstico e tratamento para pneumonia por novo coronavírus, que foram curados, que faleceram em 14 dias ou que teve acompanhamento regular por pelo menos 14 dias. Os pacientes curados ou que sobreviveram nos 14 dias foram considerados de baixo risco e os pacientes que faleceram nesse período foram considerados de alto risco. Os autores utilizaram o teste de Mann-Whitney para medir as diferenças de distribuição para variáveis contínuas e o teste Qui-quadrado para as variáveis categóricas. A significância estatística considerou um valor p menor que 0,05 em ambos os lados. Inicialmente, os autores utilizaram um método de segmentação *threshold-based* e treinaram o modelo com vários métodos de pré-processamento. Os autores construíram o modelo De-COVID19-Net com uma arquitetura 3D-CNN de 121 camadas que, segundo eles, pode sinterizar imagens de TC, sendo intuitiva e consistente com o diagnóstico dos médicos. Os autores avaliaram o desempenho do modelo utilizando a curva *Receiver Operating Characteristic* – ROC e área sob a curva – AUC. Com o intuito de verificar o seu desempenho, o modelo foi comparado com outros quatro modelos, o modelo clínico de regressão logística, baseado em dados clínicos; o modelo baseado em *radiomics*, uma ferramenta para análise de imagens médicas; o *Pure DenseNet*, que removeu a etapa de segmentação e a entrada de informações clínicas e o *DenseNet* + segmentação, que removeu somente a entrada de informações clínicas. Para realizarem os experimentos, os dados pacientes foram divididos em um grupo de treinamento com $n = 246$ e um grupo de teste com $n = 120$. Nos testes Qui-quadrado e de Mann-Whitney, não foram encontradas diferenças estatisticamente significativas. O modelo De-COVID19-Net apresentou melhor desempenho quando comparados com os outros quatro modelos e em todas as métricas. Também mostrou que possui uma excelente capacidade para diferenciar pacientes com baixo risco e alto risco e é considerado uma boa ferramenta para agilizar o combate à doença.

Alakus e Turkoglu (2020) propuseram modelos de *deep learning* para detectar a infecção por COVID-19 utilizando achados laboratoriais dos pacientes. Desta forma, é possível prever quais pacientes terão maior gravidade da doença e então gerenciar os recursos necessários. Os autores realizaram a pesquisa com 111 achados laboratoriais de 5644 pacientes atendidos no Hospital Israelita Albert Einstein do Brasil nos primeiros meses de 2020. Dentre esses pacientes, 10% apresentaram resultado positivo para a COVID-19, sendo que aproximadamente 6,5% necessitaram de hospitalização e 2,5% necessitaram de cuidados intensivos. Após um processo de balanceamentos, o número de pacientes reduziu para 600, com 18 achados laboratoriais, dentre os quais 80 pacientes foram diagnosticados com COVID-19. Os modelos desenvolvidos e treinados pelos autores para prever a infecção pela doença foram Rede Neural Artificial (RNA), Redes Neurais Convolucionais (RNC), Memória de Longo Prazo (MLP), Redes Neurais Recorrentes (RNR) e dois modelos híbridos RNCMLP e RNCNR. Os parâmetros foram escolhidos pelo método de tentativa e erro e o desempenho dos modelos foram medidos em termos de acurácia, pontuação f1, precisão, *recall* e área sob a curva (AUC). Para realizar a validação dos dados, os autores utilizaram validação cruzada (*10-fold*) e abordagem de divisão do conjunto de dados entre treinamento e teste. Os resultados dos testes mostraram que o modelo com maior valor de AUC foi o MLP, com 62,50, uma acurácia de 86,66%, pontuação f1 de 91,89% e *recall* de 99,42%. Os resultados de acurácia foram todos acima de 84% e o melhor desempenho foi obtido pelo modelo híbrido RNCMLP, com 92,30%. Os resultados da pontuação F1, precisão e *recall* estiveram acima de 84,00, os três com o modelo RNCMLP, o melhor escore de precisão com 0,9235 e o melhor resultado de *recall* com 0,9368 e a melhor pontuação F1 com 0,9300. O valor da AUC do modelo RNCNR ficou entre 0,6 e 0,8 e dos demais modelos foram superiores a 0,8. Desta forma, considerando os resultados de AUC, todos os modelos podem ser usados para aplicação de previsão clínica do COVID-19. Os autores também concluíram que modelos de *deep learning* apresentaram melhores resultados do que modelos de *machine learning*, mesmo com dados pequenos.

Shih et al. (2020) realizaram um estudo para identificar casos precoces de doença renal crônica (DRC), tendo em vista que os procedimentos atuais de triagem são inadequados para identificar a doença precoce. Desta forma, o diagnóstico precoce pode prevenir ou atenuar casos graves da DRC. Os autores consideram dois padrões para definir a DRC, o rim lesionado por mais de três meses e filtração

glomerular (TFG) $< 60 \text{ mL/min/1,73 m}^2$ por três meses. Os dados utilizados para a predição foram de exames preventivos de saúde de adultos de Taiwan. Para realizar a predição, os autores utilizaram quatro algoritmos de mineração de dados, uma árvore de classificação e regressão (CART), uma árvore de decisão (C4.5), uma análise discriminante linear (LDA) e um de aprendizado de máquina extremo (ELM). Os dados foram retirados de 19.270 exames de saúde de adultos de 32 clínicas e 3 centros de exame físico, sendo que 5.101 pacientes possuíam a doença e 14.169 pacientes sem a doença. Desses dados, 11 variáveis independentes foram identificadas e a variável dependente foi a taxa de filtração glomerular (TFG). Os autores avaliaram a precisão da classificação utilizando a área sob a curva, além de considerarem a sensibilidade e a especificidade dos modelos. Os resultados mostraram que as variáveis idade, diferença de gênero, desempenho normal ou anormal de contagem de glóbulos vermelhos (RBC), nível de glicose em jejum (GLU), triglicerídeos (TG), colesterol de lipoproteína de alta densidade (HDL), proteinúria (PRO) e relação proteína/creatinina na urina (UPCR) foram significativamente associadas a prevalência da doença. Um total de 80% dos exames dos pacientes foram utilizados como amostras de treinamento e os outros 20% como amostras de teste, além disso, um método de validação cruzada 10-fold foi usado para treinar os modelos. O modelo C4.5 apresentou o maior valor de AUC, precisão, sensibilidade e especificidade, sendo considerado com a maior capacidade para predição da doença renal crônica precoce.

Yan et al. (2020) desenvolveram uma abordagem de aprendizado de máquina para identificar casos de COVID-19 que necessitam de maior atenção médica, tendo por objetivo amenizar a escassez de recursos dos hospitais e a taxa de mortalidade. Os autores formularam o problema como uma classificação que tinha por objetivo identificar os marcadores mais importantes para distinguir pacientes graves e não-graves. Os dados de entrada do classificador foram informações básicas dos pacientes, sintomas, amostras de sangue e resultados de exames laboratoriais e resultados correspondentes a sobrevivência ou morte no final do período de exame. O desempenho dos modelos foi avaliado pela acurácia, precisão, sensibilidade/recall e pontuações F1 e os autores utilizaram um classificador *XGBoost* como modelo preditor, o qual eles denominaram de "*Multi-tree XGBoost algorithm*". De acordo com os resultados, o modelo pôde identificar com precisão a evolução dos pacientes, independente do diagnóstico da admissão hospitalar, além ser capaz de capturar os

principais biomarcadores de mortalidade, sendo o lactato desidrogenase (LDH) identificado como marcador crucial para a taxa de mortalidade dos pacientes com COVID-19. Outros dois indicadores que foram identificados para previsão de prognóstico da doença foram a proteína C-reativa (PCR) e os linfócitos. O modelo apresentou 100% de acurácia de previsão de sobrevivência e 81% de previsão de mortalidade, segundo a matriz de confusão. E ainda, os autores apresentaram que o modelo poderia prever resultados com cerca de 10 dias de antecedência a deterioração do paciente, podendo a equipe de saúde ser avisada antecipadamente da condição do paciente grave.

Moreno-Sanchez (2020) propôs um modelo de previsão explicável de sobrevivência da insuficiência cardíaca, utilizando modelos de árvores de aprendizado em conjunto (*ensemble learning trees*). O conjunto de dados utilizado pelo autor continha registros médicos de 299 pacientes que tiveram insuficiência cardíaca de um Instituto de Cardiologia e de um Hospital, ambos do Paquistão. Dentre estes, 203 pacientes sobreviventes e 96 mortos. De acordo com os autores, as técnicas de ensemble learning utilizam vários modelos para realizarem a classificação e tem um classificador base. Desta forma, os autores utilizaram a árvore de decisão como classificador base e os outros modelos *Random Forest*, *Extra Trees*, *Adaptive Boosting (Adaboost)*, *Gradient Boosting*, *eXtreme Gradient Boosting (XGBoost)*. Para seleção de recursos no pré-processamento, os autores utilizaram informação mútua, *recursive feature elimination (RFE)*, ANOVA e qui-quadrado com o objetivo de remover recursos que não contribuiriam para a classificação, reduzir o *overfitting* e o tempo de computação e melhorar a explicabilidade do modelo. Para explorar a importância dos recursos do modelo, os autores utilizaram o atributo *feature_importances*, a biblioteca Eli5, buscando a interpretabilidade global e para uma interpretabilidade local, a biblioteca SHAP (*SHapley Additive exPlanations*) foi utilizada. Para estimar o desempenho do modelo, foram utilizadas as métricas, acurácia, precisão, recall/sensibilidade, especificidade, score F1 e ROC (*Receiver Operating Characteristics*) e AUC (*Area Under The Curve*) e as métricas de explicabilidade do modelo foram interpretabilidade, fidelidade e Relação fidelidade-interpretável e a linguagem de programação utilizada foi Python. Os resultados mostraram que o *XGBoost* foi o melhor classificador em dois pipelines e o *Random Forest* em um pipeline que não foi utilizado método de seleção de recursos. Ao utilizar o conjunto de testes com o melhor modelo selecionado, o classificador *XGBoost*

obteve melhores resultados em acurácia, precisão, sensibilidade, especificidade e score F1. Os recursos com maior importância apontados nos resultados foram o tempo de acompanhamento, fração de ejeção, creatinina sérica e anemia. O recurso tempo de acompanhamento apresentou melhor atribuição em todas as técnicas, a creatinina sérica e a fração de ejeção foram menos relevantes e a anemia não apresentou uma contribuição significativa nos resultados, embora tenha sido selecionada na seleção dos recursos. O modelo desenvolvido apresentou 0,68 de acurácia, 0,68 de sensibilidade, 1 de especificidade, 0,55 de score F1 e 0,46 de precisão. Esses valores foram utilizados para calcular o desempenho de explicabilidade do melhor modelo, e apresentou 67% de interpretabilidade, 81% de fidelidade e 55% de Relação fidelidade-interpretável. Desta forma, os autores concluíram que os resultados obtidos sobre as métricas de classificação, importância dos recursos e interpretabilidade do modelo podem melhorar a previsão de sobrevida da insuficiência cardíaca.

Tariq et al. (2021) apresentaram um trabalho que prevê a probabilidade de um paciente necessitar de hospitalização futura devido ao COVID-19 quando ele realiza o teste para detectar a doença. Para isso, os autores treinaram várias arquiteturas de aprendizado de máquina usando dados de prontuários eletrônicos de antes da infecção pelo vírus, utilizando o maior número de variáveis possíveis. Os autores coletaram dados de prontuários eletrônicos de todos os pacientes que testaram positivo para COVID-19 em 12 instalações diferentes entre janeiro e setembro de 2020 e obtiveram dados de 3194 pacientes. Esses dados foram divididos entre atual e histórico, sendo o atual contendo todas as informações coletadas entre 24h e 15 dias antes do teste e o histórico contendo os dados de antes do intervalo atual. Os dados foram divididos em informações demográficas, medicamentos para pacientes internados, código que representa intervenções do paciente – CPT, comorbidades, e resultados de exames laboratoriais. Para resolver o problema, os autores utilizaram três tipos de técnicas de fusão, precoce, tardia e média, além de combiná-las com modelos de regressão logística, *random forest*, rede neural multicamada e *XGBoost*. A fusão precoce foi usada para combinar informações não imagiológicas e experimentaram os modelos de regressão logística, *random forest*, *multi-layer perceptron* e *XG Boost* para essa fusão. Na fusão tardia, o *XGBoost* foi utilizado como meta-aprendiz com base em seu desempenho. O *XGBoost* obteve melhor desempenho nos dados demográficos, medicamentos e comorbidades e o *random*

forest em códigos CPT e resultados de testes laboratoriais. Para a técnica de fusão média, os autores projetaram um modelo de rede neural ramificada. E além das técnicas de fusão, os autores propuseram modelos de aprendizado de máquina para verificar a importância de cada fonte do prontuário eletrônico na previsão. Os métodos de fusão foram comparados com os classificadores de fontes individuais e os resultados mostraram que a fusão com várias fontes teve o maior desempenho. A fusão precoce obteve melhor desempenho, com 84 de escore F1 geral e 85 de escore F1 para pacientes que precisarão de hospitalização dentro de 7 dias do teste RT-PCR. Os modelos de fusão tardia e fusão média obtiveram 83 e 82 pontos de escore F1, respectivamente. Os modelos de fusão com intervalo histórico se mostraram cruciais para a previsão, pois o resultado do modelo atual obteve uma média de 6 pontos menor do que o histórico no escore F1. De acordo com as curvas *receiver operating characteristics* -ROC e *precision-recall* (PR) os modelos de fusão também apresentaram desempenho melhor do que os classificadores individuais, com 0,91 de ROC e 0,9 de PR para a fusão precoce, 0,88 de ROC e 0,87 de PR para a fusão tardia e 0,87 de ROC e 0,87 de PR para a fusão média. A análise de calibração foi realizada para os três modelos de fusão, usando a regressão isotônica e os resultados mostraram que o modelo de fusão precoce apresentou melhor desempenho e se mostrou mais confiável na pontuação de Brier. Os resultados mostraram que, pelo modelo de fusão precoce, contagens anormais de glóbulos vermelhos, teste de dímero D, histórico de doença hipertensiva e encontros anteriores na sala de emergência são melhores para prever a hospitalização dos pacientes e os fatores demográficos raça, etnia e sexo masculino também apresentaram maior importância para a previsão. No modelo de fonte individual, as comorbidades relacionadas aos pulmões e sistemas urinários possuem maior importância nas comorbidades e o tratamento de doenças relacionadas a tireoide nos medicamentos.

McRae et al. (2020) apresentam o desenvolvimento de um bionano chip programável (p-BNC) que avalia a gravidade da COVID-19, para dar suporte a decisão clínica. Essa ferramenta realiza a medição de biomarcadores que discriminam pacientes que se recuperaram e aqueles que morreram da doença. O modelo foi treinado e validado com 160 pacientes hospitalizados com COVID-19 em Wuhan na China e após, foi realizado um estudo de caso com 12 pacientes hospitalizados com complicações da doença em Shenzhen, China. O modelo utilizado foi o de regressão logística, que desenvolveu um score de gravidade da COVID-19, usando os preditores

idade, sexo, troponina cardíaca I (cTnI), proteína C-reativa (CRP), procalcitonina (PCT) e mioglobina (MYO). Os autores utilizaram validação cruzada 5-fold para particionar os dados e para medir o desempenho do modelo utilizaram AUC, mediana (intervalo interquartil) de pontuações de gravidade de pacientes que morreram versus pacientes recuperados. A idade foi comparada usando teste t independente e as proporções por teste Qui-quadrado. Foram definidos três grupos de pacientes, sendo eles, moderados, grave e crítico. Os resultados mostraram que foram encontrados níveis mais elevados de biomarcadores cTnI, banda miocárdica de creatina quinase (CK-MB), MYO, CRP, and PCT em pacientes que morreram e a idade também foi um fator significativo com média de 63 no grupo que recebeu alta e 73 no grupo dos pacientes falecidos. As pontuações de gravidade foram maiores para pacientes falecidos e os pacientes que receberam ventilação invasiva ou não invasiva apresentaram risco intermediário de morte com pontuações de IQR de 17. Os valores de AUC do escore de gravidade multivariado da COVID-19 foi de 0,94. Ainda, 80% dos pacientes apresentaram uma pontuação de gravidade baixa com risco leve, 15% uma pontuação elevada com doença grave e 5% apresentaram um escore alto de gravidade com estado crítico da doença.

Omogbadegun et al. (2019) utilizaram Redes Neurais Artificiais (RNA) para aprender e otimizar processos no tratamento de pacientes com anemia falciforme, um distúrbio hematológico e monogênico grave, com risco de vida, que afeta milhões de pessoas em todo o mundo. A anemia falciforme apresenta maiores casos em pessoas de origens africanas, árabes e indianas. O algoritmo de RNA utilizado pelos autores pode ajudar a prever a melhor prática no gerenciamento da dor do paciente, com base nos sintomas. O algoritmo pode também determinar pacientes com maiores riscos e que precisam de atenção imediata. Com isso, pode haver uma melhora na qualidade de vida dos pacientes e evitar doenças, reduzir gastos desnecessários e melhorar a pressão sobre os profissionais por conta da quantidade de casos de emergência que precisam atender. Os dados utilizados foram de pacientes com anemia falciforme diagnosticadas e tratadas em hospitais e centros de saúde. Para fazer uma classificação, os autores separaram a doença em dor aguda baixa, dor aguda intensa, dor crônica baixa e dor crônica severa (crise). Desta forma, a RNA poderia aprender com o conjunto de dados e recomendar a melhor prática para o gerenciamento da dor do paciente com anemia falciforme.

O trabalho proposto por Bagula et al. (2017) apresenta um sistema de ciber-saúde para priorização de pacientes na cidade de Lubumbashi, na República Democrática do Congo (RDC). Esse sistema visa estabelecer uma rede de quiosques de saúde comunitários, utilizando computação em nuvem, Internet das Coisas e algoritmos de Machine Learning. Além disso, os autores avaliam o uso de um algoritmo de aprendizado não-supervisionado e comparam com modelos de aprendizado supervisionados do mesmo problema. O sistema de priorização conta com um banco de dados do histórico do prontuário dos pacientes e informações clínicas; um sistema de pontuação de risco dos parâmetros vitais, de acordo com a OMS; um aplicativo móvel de visualização para a análise dos dados e um aplicativo de servidor que realiza interface com o armazenamento na nuvem e com o aplicativo de visualização. O sistema de pontuação visa quantificar a gravidade do paciente de acordo com escores de seus sinais vitais e após isso, a condição do paciente pode ser fornecida aos usuários pelo aplicativo de visualização com os status verde se o paciente não precisar de atendimento, laranja se o paciente precisar de consulta médica e vermelho se tiver que ir ao médico imediatamente. Para resolver o problema da priorização de pacientes, os autores utilizaram dois algoritmos de machine learning Regressão Linear Multivariada (RLM), de aprendizagem supervisionado e Algoritmo de agrupamento *K-means*, de aprendizado não supervisionado. No algoritmo RLM, os autores utilizaram o método do gradiente descendente, que utilizou um sistema baseado em conhecimento que aprende com os dados, calcula os pesos para cada variável ou gera uma hipótese linear para pontuar os parâmetros vitais. No algoritmo *K-means*, os dados são particionados em clusters com o algoritmo gaussiano *Parzen window estimator*, para estimar uma função de densidade de probabilidade que calcula o status do paciente. Os algoritmos foram comparados com a utilização de quatro parâmetros, dentre eles, coeficiente de determinação, acurácia, tempo de execução e complexidade de tempo, enquanto o método de Análise de Variância (ANOVA) foi utilizado para avaliar os modelos. Os dados de pacientes reais foram utilizados para treinar e comparar os algoritmos e os resultados experimentais mostraram o RLM obteve um tempo computacional de 5 segundos e uma acurácia de 90% enquanto o K-means obteve tempo computacional de 14,22 segundos e não apresenta valor de acurácia. Desta forma, os autores encontraram a maior eficiência no algoritmo RLM, com base nos resultados obtidos.

Mandava et al. (2016) apresentaram um sistema de *Cyberhealthcare* que tinha por objetivo realizar a priorização de pacientes, usando técnicas de aprendizado de máquina. O sistema conta com médicos que atendem e tratam pacientes virtualmente pela internet e utiliza equipamentos de e-saúde que verifica sinais vitais dos pacientes. Os sinais vitais são capturados por redes de sensores corporais, são armazenados e depois retransmitidos para análise de dados e gerenciamento da situação do paciente. A priorização de pacientes é feita com uma atribuição de pontuação aos sinais vitais dos pacientes de modo a quantificar a gravidade em que ele se encontra. Algumas vantagens que o sistema de *Cyberhealthcare* gera são a priorização de pacientes que auxilia profissionais de saúde na tomada de decisão; monitoramento periódico e remoto em tempo real dos pacientes; economia de tempo, pois desobriga o enfermeiro de fazer leituras dos sinais vitais dos pacientes, precisão da captura dos sinais vitais e economia de custos, pois um kit de e-saúde pode ser usado por muitos pacientes. Os algoritmos de Machine Learning utilizados foram a Regressão Linear Multivariada por Gradiente Descendente (RLM) e *Support Vector Machine* (SVM). O primeiro algoritmo, pontua os dados de treinamento antes do treinamento, utilizando o sistema baseado em conhecimento, que aprende com os dados, calcula os pesos das variáveis ou gera uma hipótese linear para pontuar os parâmetros. O segundo algoritmo, também usa o sistema baseado em conhecimento para pontuar os dados de treinamento antes do treinamento, ele recebe os dados de entrada e saída e os dimensiona e após isso, ele aprende usando funções lineares gerando um modelo a partir dos dados de treinamento. Os autores realizaram um experimento para comparar os dois algoritmos RLM e SVM e os resultados obtidos mostraram que o algoritmo RLM levou aproximadamente 5 segundos para calcular a prioridade dos pacientes e obteve uma acurácia de 90% enquanto o SVM obteve um tempo de 10,20 segundos e uma acurácia de 80,67%. Os autores também constataram que quanto mais dados tiverem disponíveis, é esperado uma melhora na acurácia do algoritmo.

Neves et al. (2001) implementaram um sistema inteligente para resolver a elegibilidade e prioridade de pacientes que esperam por um transplante de medula óssea no Hospital das Clínicas da UFPR, na cidade de Curitiba localizada no Brasil, pois há uma grande fila espera para a realização do transplante, com mais de 300 candidatos. Os critérios que os autores utilizaram foram retirados da literatura e da experiência do serviço de transplante de medula óssea, dentre eles estão as

características demográficas, os diagnósticos prévio e/ou atual dos pacientes, resultados laboratoriais, sintomas, achados de exame físico e medicamentos atuais ou anteriores. Para resolver o problema, os autores definiram três etapas, aquisição de conhecimento, determinação da elegibilidade e determinação da prioridade. Na primeira etapa, foram revisados os critérios e as variáveis para determinar a elegibilidade e a prioridade. Na determinação da elegibilidade, os pacientes são incluídos ou excluídos por meio de critérios específicos e as regras de elegibilidade foram baseadas nos regulamentos técnicos do Ministério da Saúde do Brasil adaptados pelos especialistas do serviço de transplante de medula óssea. Na etapa da determinação da prioridade os autores fizeram extensas análises comparando as condições em que os pacientes tiveram maior probabilidade de sucesso com o transplante. Essa etapa foi dividida em duas fases, qualitativa e quantitativa, na primeira fase foram utilizados os critérios e as variáveis para o diagnóstico da Leucemia Mieloide Crônica (LMC) e na segunda fase os valores de probabilidade associados aos critérios foram definidos, os quais foram obtidos por probabilidades condicionais e a priori dos exemplos do banco de dados pós-transplante, do serviço de transplante de medula óssea. O método Kaplan Meier foi utilizado para analisar o banco de dados pós-transplante, tendo em vista determinar o período mais adequado para submeter os candidatos ao transplante. Os critérios para a elegibilidade foram implementados na ferramenta *shell Expert* e a técnica utilizada para a priorização foi a *shell Nética*, a qual também gerou as probabilidades condicionais. Neste projeto, especialistas com anos de experiência e prática especializada em hemato-oncologia participaram de todas as etapas. A avaliação do sistema foi realizada comparando seus resultados com as normas técnicas do Ministério da Saúde do Brasil e com os critérios dos especialistas. Para a validade do sistema, casos reais foram testados e os autores verificaram que o sistema foi capaz de determinar a elegibilidade de todos os pacientes com diagnóstico de LMC, mostrando também a prioridade. Para a prioridade, o sistema apresentou dificuldades em apresentar o teste que deveria ser aplicado, então foi utilizado um teste de confiabilidade e os especialistas criaram uma linha única de prioridade, para criar um padrão de referência baseado na literatura, mas não houve muita concordância na primeira avaliação com o sistema. Assim, foram feitos novos ajustes na base de conhecimento e a avaliação do resultado da priorização melhorou. Na análise final, os resultados mostraram que era preciso favorecer o paciente com maior probabilidade de sucesso com o transplante e no caso

de apresentarem a mesma probabilidade, a prioridade era de quem estava mais tempo na fila de espera. Os autores constataram que embora o sistema não resolvesse completamente o problema da fila de espera, ele ajuda o especialista a eleger e definir prioridades para o transplante de medula óssea.

Free et al. (2023) propuseram uma abordagem de apoio a decisão clínica para gerenciar internações por pneumonia adquirida na comunidade. Segundo os autores, essa pneumonia é a principal causa de morte nos hospitais do Reino Unido e gera custos altos. Mas, se tratada com intervenções imediatas os resultados são significativamente melhores. A abordagem utilizada na resolução desse problema foi a utilização de uma estrutura de software genérica chamada *Embeddable AI e State-based Understanding Logic* (EASUL). Os autores compararam o nível de gravidade atribuída pela equipe de saúde com o nível determinado pelo EASUL, baseando-se em um escore clínico utilizado no Reino Unido considerando presença/ausência de confusão mental; uréia sanguínea elevada; alta frequência respiratória; pressão sanguínea baixa; e idade (em ou acima de 65 anos). Com isso, a gravidade da doença é classificada como baixa, moderada ou alta. O conjunto de dados tinha 52.471 pacientes adultos e os resultados mostraram que, comparando os resultados do EASUL com as respostas da equipe de saúde, apenas 49,4% das respostas tiveram a mesma gravidade pelos dois processos. Esse resultado foi analisado e para verificar se a comparação estava correta, os dados de uma proporção de pacientes foram classificados de forma diferente pela EASUL e pela equipe de saúde os quais realizavam a análise manualmente. Com isso, constatou-se que alguns pacientes tinham sido analisados de forma incorreta pela equipe de saúde. Os autores mencionaram que existem vários motivos para ocorrer essa análise incorreta, dentre eles, dados faltantes ou perdidos, resultados registrados posteriormente, pacientes recebendo alta antes da revisão, dentre outros. Portanto, os autores demonstraram a efetividade da abordagem proposta para ferramentas de apoio a decisão e a utilidade na priorização e triagem de pacientes.

Jegatheeswaran e Tolley (2022) propuseram uma abordagem de priorização de pacientes com tireoidectomia e paratireoidectomia na fila de espera para a cirurgia, num hospital de Londres. Para isso, os autores utilizaram um modelo de inteligência aumentada chamado COMPASS SLT. De acordo com os autores, havia 377.689 pacientes na fila de espera e devido a pandemia as cirurgias atrasaram ainda mais. O COMPASS foi utilizado para obter o risco geral de morte dos pacientes, o risco geral

de complicações, a lista de todas as complicações com risco acima de 2,5% e o efeito geral no risco de mortalidade e morbidade. Dessa forma, o COMPASS foi utilizado para acrescentar informações adicionais na priorização feita por diretrizes estabelecidas por associações da área de endocrinologia. Assim, segundo os autores, o COMPASS pode auxiliar na tomada de decisões na área da saúde, fornecendo aos médicos objetividade e flexibilidade, podendo oferecer informações importantes sobre a morbidade e a mortalidade dos pacientes.

Abdel-Hafez et al. (2023) desenvolveram um método de inteligência artificial para automatizar encaminhamentos médicos para serviços ambulatoriais na especialidade de otorrinolaringológica, em Queensland. Esse método foi elaborado com base em critérios desenvolvidos por um conjunto de diretrizes clínicas para que esses encaminhamentos sejam realizados. Segundo os autores, esses encaminhamentos eram feitos manualmente e separados em três categorias. Então, para proporcionar um acesso equitativo para os pacientes aos serviços ambulatoriais e reduzir o tempo gasto na triagem dos pacientes, os autores propuseram essa abordagem. Para resolver esse problema, os autores realizaram um pré-processamento dos critérios e a coleta de dados referentes aos encaminhamentos, que no total foram 17.378 encaminhamentos. Após, os autores utilizaram métodos de previsão para prever em qual categoria os pacientes se encaixavam. Os métodos utilizados foram “*Text similarity*”, “*K-nearest neighbour*” (KNN), “*Supervised learning methods*”, “*Semi-supervised learning*” e “*Unsupervised learning using K-means clustering*”. Para avaliar o desempenho dos métodos propostos, os autores compararam os resultados das categorias reais e das categorias previstas e mediram a concordância entre esses resultados. Além disso, os autores calcularam a precisão e a sensibilidade de cada categoria. Com isso, o método de maior desempenho foi o “*Text similarity*” e a categoria de maior desempenho foi a terceira, com precisão de 63,8% e sensibilidade de 64,4%. Os autores também constataram que a distância de Levenshtein é uma medida mais eficaz de similaridade. Dessa forma, o método proposto foi considerado promissor para apoiar os médicos na categorização eficiente dos pacientes nos encaminhamentos médicos.

Wee et al. (2022) também propuseram uma abordagem para a triagem de encaminhamento de pacientes para atendimento especializado em Queensland. Os autores mencionaram que essa triagem é realizada manualmente por grupos de médicos, com base na urgência do atendimento, mas esse é um processo demorado.

A triagem é realizada com base nos Critérios de Priorização Clínica e os encaminhamentos são categorizados em três categorias: urgente, urgência moderada e não urgente. Os critérios de Priorização são escritos em textos pelos médicos, gerando variações no conteúdo e na estrutura dos textos. Para resolver esse problema, os autores utilizaram técnicas de Processamento em Linguagem Natural (PNL), a qual extrai significados de textos, convertendo as referências não estruturadas e dados estruturados. Assim, o objetivo dos autores com esse trabalho é fornecer um processo de triagem de encaminhamento médico, baseado nos critérios, sem necessitar de um conjunto de dados de triagem anterior. Além da PNL, os autores também utilizaram a similaridade de cosseno para medir a similaridade dos documentos na análise de texto. Os autores utilizaram 3000 encaminhamentos médicos da área de otorrinolaringologia entre 2019 e 2020 para realizarem o teste experimental da pesquisa. Inicialmente eles avaliaram a lógica da busca com similaridade de uma referência em relação aos critérios, depois encontraram a precisão da lógica em relação ao conjunto de encaminhamentos utilizados. As métricas de avaliação do experimento foram: sensibilidade, especificidade, precisão e pontuação F1. Os resultados do teste apresentaram uma pontuação Micro F1 de 0,98, mostrando o bom desempenho do sistema de encaminhamento proposto. Dessa forma, os autores concluíram que a abordagem proposta por eles pode ajudar nos encaminhamentos de saúde, proporcionando o gerenciamento eficientes dos encaminhamentos dos pacientes.

Kim et al. (2024) apresentaram uma técnica de conjunto de empilhamento adaptativo para identificar e classificar níveis de gravidade da COVID-19 em pacientes que apresentaram a doença. Os níveis de gravidade podem ser previstos com três tipos de saída, tipo1 (gravidade baixa ou alta), tipo 2 (leve, grave e crítico) ou tipo 3 (assintomático, leve, moderado, grave e fatal). Os autores destacaram três contribuições desse trabalho, as quais são um grande conjunto de dados, com 5644 pacientes com COVID-19; uma estratégia de dados para a classificação da gravidade usando apenas as variáveis clínicas disponíveis e o conjunto de empilhamento adaptativo que combina vários classificadores. Para a resolução desse problema, os autores propuseram o método em cinco fases. A primeira fase é o “pré-processamento dos dados”, na qual são removidas informações irrelevantes e incluídos valores faltantes, além de realizarem uma padronização dos dados e uma codificação das características categóricas. A segunda fase se trata da “estratégia baseada em

dados”, onde os autores criam grupos de variáveis clínicas, considerando a disponibilidade dessas variáveis. A terceira fase se trata da “seleção de recursos”, para identificar os recursos que afetam significativamente a previsão da gravidade da doença. Na quarta fase, “divisão e sobreamostragem de dados”, os autores dividem os dados em subconjuntos de treinamento e teste e para realizar a sobreamostragem, utilizam duas técnicas a Técnica de Sobreamostragem Minoritária Sintética (SMOTE) e Adaptativa Amostragem Sintética (ADASYN). A quinta fase é a “construção do modelo de conjunto de empilhamento”, que utiliza de vários modelos para realizar as previsões, “*LogisticRegression* (LR)”, “*Support Vector Machine1* (SVM1)”, “*Stochastic Gradient Descent* (SGD)”, “*Support Vector Machine 2* (SVM2)”, “*Multi-Layer Perceptron* (MLP)”, “*K-Nearest Neighbor* (KNN)”, “*Gaussian Naïve Bayes* (GNB)”, “*Extra Trees Classifier* (ExTree)”, “*Decision Tree* (DT)”, “*XGBoost* (XGB)”, “*Light Gradient Boosting Machine* (LGBM)”, “*AdaBoost* (ADA)”, “*Random Forest* (RF)” e “*CatBoost* (CAT)”. Para verificar o desempenho da técnica proposta, os autores realizaram três experimentos, um para avaliar o desempenho dos modelos de predição, outro para verificar a eficácia da estratégia baseada em dados e sobreamostragem e outro para verificar o efeito do algoritmo de seleção de recursos. As métricas utilizadas foram precisão, recall, pontuação F1, especificidade e pontuação AUC. Dessa forma, os resultados mostraram que o modelo proposto demonstrou uma robustez considerável, com uma pontuação F1 média de 0,9588 e uma pontuação AUC de 0,9380 em toda a região. Em comparação com outros classificadores existentes, o modelo abordado pelos autores os superou significativamente, com melhorias de 6,42% e 8,86% nas pontuações F1 e AUC para o Tipo 1, 9,59% e 6,68% para o Tipo 2 e 11,94% e 9,24%. para o Tipo 3. Assim, os autores concluíram que essa abordagem pode melhorar a previsão nos níveis de gravidade da COVID-19, contribuindo para a tomada de decisão na área da saúde.

QUADRO 2 - TRABALHOS QUE ABORDARAM PROBLEMAS DE PRIORIZAÇÃO UTILIZANDO MÉTODOS DE INTELIGÊNCIA ARTIFICIAL

Autores/ano	Problema Abordado	Método de resolução	Resultados
Shashikumar et al. (2021)	Previsão do início da sepse em pacientes.	Modelo de <i>deep learning</i> denominado COMPOSER que: - Dimensiona o valor de uma variável clínica de acordo com o tempo desde a última medição.	Comparando com um modelo de rede neural <i>feedforward</i> , na UTI do hospital B o COMPOSER apresentou aproximadamente 85,5% de redução em relação a alarmes falsos e 0,925 vs 0,910 da área sob a curva e de 24,3% vs 23% do valor preditivo positivo,

		<ul style="list-style-type: none"> - Preditor que avalia a conformidade de uma nova instancia de teste. - Rede neural <i>feedforward</i> que prediz o risco de sepse. 	<p>comparando o COMPOSER com outro modelo, respectivamente. Os autores também realizaram uma validação temporal na UTI e no departamento de emergência do hospital A e obteve uma área sob a curva de 0,940 no departamento de emergência e 0,952 na UTI, mantendo baixa a taxa de alarme falso, que foi de 0,047 no departamento de emergência e de 0,029 na UTI. Também na validação temporal, ao ser comparado com um modelo de predição de sepse do hospital A, modelo reduziu aproximadamente 78% de alarmes falsos, no mesmo período, e obteve uma melhoria significativa no tempo da notificação da sepse em relação ao modelo do hospital.</p>
Goncharov et al. (2021)	Identificar pacientes com Covid-19 por meio da análise de exames de tomografia computadorizada de tórax e quantificar a gravidade da doença em cada paciente.	<ul style="list-style-type: none"> - Pré-processamento para realizar uma segmentação dos pulmões, para ambos os pulmões, utilizaram uma rede neural totalmente convolucional e para máscaras separadas dos pulmões esquerdo e direito, um agrupamento com o algoritmo <i>k-means</i>; - Quantificar a gravidade da doença utilizando métodos baseados em limiarização; - Identificação da doença em que uma das tarefas utiliza resultados da segmentação para identificar os pacientes com determinadas lesões e a segunda tarefa utiliza uma rede neural para classificar os pacientes como positivos ou negativos para a doença. - Abordagem que resolve a tarefa de identificação e de segmentação simultaneamente, utilizando uma rede neural convolucional de duas cabeças. 	<p>Os resultados dos experimentos mostraram que os modelos baseados em segmentação apresentaram um desempenho baixo ao classificar Covid-19 e pneumonia bacteriana. A classificação da doença utilizando rede neural apresentou resultados de área sob a curva altos, porém instáveis. Por fim, o modelo multitarefas superou o modelo anterior em relação a identificação, além de obter mais estabilidade. Este modelo também distingue com mais precisão o Covid-19 das outras doenças pulmonares. Desta forma, este trabalho mostrou que o modelo multitarefas é útil para a identificação e para a classificação do Covid-19</p>
Wang et al. (2021)	Investigar resultados ruins da Covid-19	- Um modelo de <i>deep learning</i> e um modelo de	O modelo híbrido superou os outros modelos, com AUC de

	em pacientes que já apresentavam condições de saúde subjacentes.	radiômica foram desenvolvidos, ambos para prever a probabilidade de obter resultados ruins; - Um modelo de regressão logística multivariada para reunir probabilidades dos dois modelos, formando um modelo híbrido.	0,876, além de apresentar maior desempenho, robustez e grande capacidade de estratificação de risco. E o modelo híbrido de recursos obteve AUC de 0,786. Além disso, as curvas de sobrevida mostraram que pacientes com COVID-19 com várias condições de saúde subjacentes apresentaram maior risco de morte
Quiroz et al. (2021)	Previsão da gravidade da COVID-19 utilizando dados clínicos e de imagens de pacientes que testaram positivo para a doença.	- Pré-processamento e segmentação pulmonar usando um modelo denominado de 'R231CovidWeb'; -Para prever a gravidade da doença foram utilizados três modelos LR (com <i>scikit-learn</i>), gradiente <i>boosted trees</i> (XGBoost) e um NN (fast.ai). - Quatro métodos de sobreamostragem para aumentar a proporção a classe minoritária. Os métodos foram <i>synthetic minority oversampling (SMOTE)</i> , <i>Adaptive Synthetic Sampling</i> , <i>geometric SMOTE</i> e um modelo <i>conditional generative adversarial network (CTGAN)</i> para dados tabulares.	A idade média dos pacientes dos grupos leve/comum foi de 48,5 anos e dos pacientes do grupo grave/crítico foi de 63 anos. Em relação as comorbidades, doença cardiovascular, hipertensão, diabetes e câncer foram mais encontradas nos pacientes dos grupos grave/crítico. E em relação aos sintomas, aumento da frequência respiratória e dispneia foram mais comum nos grupos grave/crítico. O modelo LR obteve maior desempenho e os resultados de imagem apresentaram melhores do que os recursos clínicos e a combinação de imagem e recursos clínicos favoreceu somente o modelo LR. A sobreamostragem SMOTE melhorou o desempenho do modelo e os resultados mostraram que o aumento nas características de imagem volume de consolidação, volume total da lesão, volume em vidro fosco e volume de outras anormalidades tem maior probabilidade de prever caso grave/crítico. Outras características que apareceram como maior probabilidade de ocorrer caso grave/crítico foram baixos níveis de albumina, altos níveis de proteína C reativa, alta contagem de leucócitos e baixos níveis de lactato desidrogenase, a idade e o sexo masculino.
Meng et al. (2020)	Prever o risco de morte de pacientes com COVID-19, de forma não invasiva, considerando resultados de tomografia computadorizada (TC) e informações clínicas	- Rede neural convolucional 3D (3D-CNN) denominada De-COVID19-Net que prevê a probabilidade de morte dos pacientes em duas semanas. - O modelo foi comparado com outros quatro modelos, o modelo clínico	O modelo De-COVID19-Net apresentou melhor desempenho quando comparados com os outros quatro modelos e em todas as métricas. Também mostrou que possui uma excelente capacidade para diferenciar pacientes com baixo risco e alto risco e é considerado uma boa ferramenta para agilizar o combate a doença.

		de regressão logística, baseado em dados clínicos; o modelo baseado em <i>radiomics</i> , uma ferramenta para análise de imagens médicas.	
Alakus e Turkoglu (2020)	Detectar a infecção por COVID-19 utilizando achados laboratoriais dos pacientes, de forma a prever quais pacientes terão maior gravidade da doença e então gerenciar os recursos necessários	Os modelos desenvolvidos e treinados para prever a infecção pela doença foram: - Rede Neural Artificial (RNA); - Redes Neurais Convolucionais (RNC); - Memória de Longo Prazo (MLP); - Redes Neurais Recorrentes (RNR); - RNCMLP (modelos híbridos); - RNCRNR (modelos híbridos).	O modelo com maior valor de AUC foi o MLP, com 62,50, uma acurácia de 86,66%, pontuação f1 de 91,89% e recall de 99,42%. Os resultados de acurácia foram todos acima de 84% e o melhor desempenho foi obtido pelo modelo híbrido RNCMLP, com 92,30%. Os resultados da pontuação F1, precisão e <i>recall</i> estiveram acima de 84,00, os três com o modelo RNCMLP, o melhor score de precisão com 0,9235 e o melhor resultado de <i>recall</i> com 0,9368 e a melhor pontuação F1 com 0,9300. O valor da AUC do modelo RNCRNR ficou entre 0,6 e 0,8 e dos demais modelos foram superiores a 0,8.
Shih et al. (2020)	Identificar casos precoces de doença renal crônica (DRC), tendo em vista que os procedimentos atuais de triagem são inadequados para identificar a doença precoce.	Para realizar a predição, foram utilizados: - Quatro algoritmos de mineração de dados; - Uma árvore de classificação e regressão (CART); - Uma árvore de decisão C4.5, - Uma análise discriminante linear (LDA) - Uma máquina de aprendizado extremo (ELM).	Os resultados mostraram que as variáveis idade, diferença de gênero, desempenho normal ou anormal de contagem de glóbulos vermelhos (RBC), nível de glicose em jejum (GLU), triglicerídeos (TG), colesterol de lipoproteína de alta densidade (HDL), proteinúria (PRO) e relação proteína/creatinina na urina (UPCR) foram significativamente associadas a prevalência da doença. O modelo C4.5 apresentou o maior valor de AUC, precisão, sensibilidade e especificidade, sendo considerado com a maior capacidade para predição da doença renal crônica precoce.
Yan et al. (2020)	Identificar casos de COVID-19 que necessitam de maior atenção médica.	- Um classificador <i>XGBoost</i> foi utilizado como modelo preditor, o qual eles denominaram de ' <i>Multi-tree XGBoost algorithm</i> '.	O modelo pôde identificar com precisão a evolução dos pacientes, independente do diagnóstico da admissão hospitalar, além ser capaz de capturar os principais biomarcadores de mortalidade, sendo o <i>lactato desidrogenase</i> (LDH) identificado como marcador crucial para a taxa de mortalidade dos pacientes com COVID-19. Outros dois indicadores que foram

			identificados para previsão de prognóstico da doença foram a proteína C-reativa (PCR) e os linfócitos. O modelo apresentou 100% de acurácia de previsão de sobrevida e 81% de previsão de mortalidade, segundo a matriz de confusão. E ainda, os autores apresentaram que o modelo poderia prever resultados com cerca de 10 dias de antecedência a deterioração do paciente.
Moreno-Sanchez (2020)	Prever a sobrevivência da insuficiência cardíaca,	<ul style="list-style-type: none"> - Árvore de decisão como classificador base - <i>Random Forest</i>; - <i>Extra Trees</i> - <i>Adaptive Boosting (Adaboost)</i>; - <i>Gradient Boosting</i>; - <i>eXtreme Gradient Boosting (XGBoost)</i>. 	O XGBoost foi o melhor classificador em dois pipelines e o Random Forest em um pipeline que não foi utilizado método de seleção de recursos. Ao utilizar o conjunto de testes com o melhor modelo selecionado, o classificador XGBoost obteve melhores resultados em acurácia, precisão, sensibilidade, especificidade e score F1. Os recursos com maior importância apontados nos resultados foram o período de tempo de acompanhamento, fração de ejeção, creatinina sérica e anemia. Esses valores foram utilizados para calcular o desempenho de explicabilidade do melhor modelo, e apresentou 67% de interpretabilidade, 81% de fidelidade e 55% de Relação fidelidade-interpretável.
Tariq et al. (2021)	Previsão da probabilidade de um paciente necessitar de hospitalização futura devido ao COVID-19 quando ele realiza o teste para detectar a doença	<ul style="list-style-type: none"> - Modelo de fusão precoce para combinar informações não imagiológicas e experimentaram os modelos de regressão logística, <i>random forest</i>, <i>multi-layer perceptron</i> e <i>XG Boost</i> para essa fusão; - Na fusão tardia, o <i>XGBoost</i> foi utilizado como meta-aprendiz com base em seu desempenho; - Para a técnica de fusão média, os autores projetaram um modelo de rede neural ramificada; - E além das técnicas de fusão, os autores propuseram modelos de 	Os métodos de fusão foram comparados com os classificadores de fontes individuais e os resultados mostraram que a fusão com várias fontes teve o maior desempenho e a fusão precoce obteve melhor desempenho entre os métodos de fusão. Os resultados mostraram que, pelo modelo de fusão precoce, contagens anormais de glóbulos vermelhos, teste de dímero D, histórico de doença hipertensiva e encontros anteriores na sala de emergência são melhores para prever a hospitalização dos pacientes e os fatores demográficos raça, etnia e sexo masculino também apresentaram maior importância para a previsão. No modelo de fonte individual, as comorbidades relacionadas aos pulmões e sistemas urinários possuem maior importância nas comorbidades e o

		aprendizado de máquina para verificar a importância de cada fonte do prontuário eletrônico na previsão.	tratamento de doenças relacionadas a tireoide nos medicamentos.
McRae et al. (2020)	Avaliação da gravidade da COVID-19, para dar suporte a decisão clínica	Um modelo de regressão logística foi utilizado para desenvolver um score de gravidade da COVID-19.	Foram encontrados níveis mais elevados de biomarcadores cTnl, banda miocárdica de creatina quinase (CK-MB), MYO, CRP, e PCT em pacientes que morreram e a idade também foi um fator significativo com média de 63 no grupo que recebeu alta e 73 no grupo dos pacientes falecidos. As pontuações de gravidade foram maiores para pacientes falecidos e os pacientes que receberam ventilação invasiva ou não invasiva apresentaram risco intermediário de morte com pontuações de IQR de 17. Os valores de AUC do escore de gravidade do COVID-19 multivariado foi de 0,94. Ainda, 80% dos pacientes apresentaram uma pontuação de gravidade baixa com risco leve, 15% uma pontuação elevada com doença grave e 5% apresentaram um escore alto de gravidade com estado crítico da doença.
Omogbadegun, Ogundele e Oladipupo (2019)	Aprendizado e otimização de processos no tratamento de pacientes com anemia falciforme.	Redes Neurais Artificiais (RNA) para ajudar a prever a melhor prática no gerenciamento da dor do paciente, com base nos sintomas.	Para fazer uma classificação, a doença foi separada em dor aguda baixa, dor aguda intensa, dor crônica baixa e dor crônica severa (crise). Desta forma, a RNA poderia aprender com o conjunto de dados e recomendar a melhor prática para o gerenciamento da dor do paciente com anemia falciforme.
Bagula et al. (2017)	Priorização de pacientes visando estabelecer uma rede de quiosques de saúde comunitários.	- Algoritmo de machine learning Regressão Linear Multivariada (RLM), de aprendizagem supervisionado; - Algoritmo de agrupamento <i>K-means</i> , de aprendizado não supervisionado.	Os resultados experimentais mostraram o RLM obteve um tempo computacional de 5 segundos e uma acurácia de 90% enquanto o <i>K-means</i> obteve tempo computacional de 14,22 segundos e não apresenta valor de acurácia. Desta forma, os autores consideraram maior eficiência do algoritmo RLM, com base nos resultados obtidos.
Mandava et al. (2016)	Priorização de pacientes, usando técnicas de aprendizado de	Os algoritmos de Machine Learning utilizados foram:	Os resultados obtidos mostraram que o algoritmo RLM levou aproximadamente 5 segundos para calcular a prioridade dos

	máquina, utilizando equipamentos de e-saúde que verifica sinais vitais dos pacientes	<ul style="list-style-type: none"> - Regressão Linear Multivariada por Gradiente Descendente (RLM); - Máquina de Vetores de Suporte (MVS). 	pacientes e obteve uma acurácia de 90% enquanto o MVS obteve um tempo de 10,20 segundos e uma acurácia de 80,67%. Os autores também constataram que quanto mais dados tiverem disponíveis, é esperado uma melhora na acurácia do algoritmo.
Neves et al. (2001)	Resolver a elegibilidade e prioridade de pacientes que esperam por um transplante de medula óssea	<ul style="list-style-type: none"> - Os critérios para a elegibilidade foram implementados na ferramenta <i>shell Expert</i>; - A técnica utilizada para a priorização foi a <i>shell Nética</i>, a qual também gerou as probabilidades condicionais. 	Os resultados mostraram que era preciso favorecer o paciente com maior probabilidade de sucesso com o transplante e no caso de apresentarem a mesma probabilidade, a prioridade era de quem estava mais tempo na fila de espera. Os autores constataram que embora o sistema não resolvesse completamente o problema da fila de espera, ele ajuda do especialista a eleger e definir prioridades para o transplante de medula óssea.
Free et al. (2023)	Gerenciamento de internações por pneumonia adquirida na comunidade.	Uma estrutura de software genérica chamada <i>Embeddable AI e State-based Understanding Logic</i> (EASUL)	Os resultados mostraram que, comparando os resultados do EASUL com as respostas da equipe de saúde, apenas 49,4% das respostas tiveram a mesma gravidade pelos dois processos. Esse resultado foi analisado e para verificar se a comparação estava correta os dados de uma proporção de pacientes foram classificados de forma diferente pela EASUL e pela equipe de saúde e foram analisados manualmente. Com isso, constatou-se que alguns pacientes tinham sido analisados de forma incorreta pela equipe de saúde. Os autores demonstraram a efetividade da abordagem proposta para ferramentas de apoio a decisão e a utilidade na priorização e triagem de pacientes.
Jegatheeswaran e Tolley (2022)	Priorização de pacientes com tireoidectomia e paratireoidectomia na fila de espera para a cirurgia num hospital de Londres.	Modelo de inteligência aumentada chamado COMPASS SLT.	O COMPASS foi utilizado para acrescentar informações adicionais na priorização feita por diretrizes estabelecidas por associações da área de endocrinologia. Os autores constataram que o COMPASS pode auxiliar na tomada de decisões na área da saúde, fornecendo aos médicos objetividade e flexibilidade, podendo oferecer informações

			importantes sobre a morbidade e a mortalidade dos pacientes.
Abdel-Hafez et al. (2023)	Automatização de encaminhamentos médicos para serviços ambulatoriais para a especialidade de otorrinolaringológica, em Queensland.	<ul style="list-style-type: none"> - <i>Text similarity</i>; - <i>K-nearest neighbour</i> (KNN); - <i>Supervised learning methods</i>; - <i>Semi-supervised learning</i>; - <i>Unsupervised learning using K-means clustering</i>. 	O método de maior desempenho foi o " <i>Text similarity</i> " e a categoria de maior desempenho foi a terceira, com precisão de 63,8% e sensibilidade de 64,4%. Os autores também constataram que a distância de Levenshtein é uma medida mais eficaz de similaridade. Dessa forma, o método proposto foi considerado promissor para apoiar os médicos na categorização eficiente dos pacientes nos encaminhamentos médicos.
Wee et al. (2022)	Triagem de encaminhamento de pacientes para atendimento especializado em Queensland.	Técnicas de Processamento em Linguagem Natural (PNL).	Os resultados do teste apresentaram uma pontuação Micro F1 de 0,98, mostrando o bom desempenho do sistema de encaminhamento proposto. Dessa forma, os autores concluíram que a abordagem proposta por eles pode ajudar nos encaminhamentos de saúde, proporcionando o gerenciamento eficientes dos encaminhamentos dos pacientes.
Kim et al. (2024)	Identificação e classificação níveis de gravidade da COVID-19 em pacientes que apresentaram a doença.	<p>Técnica de conjunto de empilhamento adaptativo:</p> <ul style="list-style-type: none"> - Para realizar a sobreamostragem: Técnica de Sobreamostragem Minoritária Sintética (SMOTE) e Adaptativa Amostragem Sintética (ADASYN); - Modelos de previsão que compõem o conjunto de empilhamento: <i>LogisticRegression</i> (LR), <i>Support Vector Machine1</i> (SVM1), <i>Stochastic Gradient Descent</i> (SGD), <i>Support Vector Machine 2</i> (SVM2), <i>Multi-Layer Perceptron</i> (MLP), <i>K-Nearest Neighbor</i> (KNN), <i>Gaussian Naïve Bayes</i> (GNB), <i>Extra Trees Classifier</i> (ExTree), <i>Decision Tree</i> (DT), <i>XGBoost</i> (XGB), <i>Light Gradient Boosting Machine</i> (LGBM), <i>AdaBoost</i> (ADA), <i>Random Forest</i> (RF) e <i>CatBoost</i> (CAT). 	Os resultados mostraram que o modelo proposto demonstrou uma robustez considerável, com uma pontuação F1 média de 0,9588 e uma pontuação AUC de 0,9380 em toda a região. Assim, os autores concluíram que essa abordagem pode melhorar a previsão nos níveis de gravidade da COVID-19, contribuindo para a tomada de decisão na área da saúde.

FONTE: A autora (2022).

Os vinte artigos selecionados nessa revisão tiveram anos de publicação entre 2001-2024, sendo um artigo de 2001, dois de 2016, um de 2019, seis de 2020, cinco de 2021, dois de 2022, dois de 2023 e um de 2024. Dentre os temas abordados, um era sobre sepse, nove eram sobre a COVID-19, um sobre doença renal, um sobre insuficiência cardíaca, um sobre anemia falciforme, um sobre rede de quiosques de saúde comunitários, um sobre equipamentos de e-saúde que verifica sinais vitais, um sobre transplante medula óssea, um sobre encaminhamento para atendimento especializado, um sobre encaminhamentos para otorrinolaringologia, um sobre tireoidectomia e um sobre pneumonia. Dos métodos propostos mais utilizados, seis trabalhos utilizaram redes neurais, cinco utilizaram *XGBoost* e quatro utilizaram regressão logística. Além dos outros métodos já mencionados.

Os trabalhos abordados mostraram que métodos de IA podem ser ferramentas poderosas no auxílio a decisão clínica, sendo em problemas de previsão de gravidade das doenças, análises de exames, otimização em processos de tratamento, gerenciamentos de internações, priorização e classificação dos pacientes. Considerando que, geralmente, esses encaminhamentos e triagens são realizados manualmente pelos profissionais da saúde, essas ferramentas podem proporcionar agilidade nos atendimentos e tratamentos, redução de custos, maiores chances de recuperação, entre outros benefícios.

Nesses trabalhos, também é interessante destacar que a maioria dos artigos se trata da COVID-19 e alguns fazem a separação em categorias de acordo com níveis de gravidade, como nos trabalhos sobre o AHP. Outro ponto a ser considerado é a frequência das redes neurais nos trabalhos e o bom desempenho desse método nos problemas de priorização de pacientes. Os modelos híbridos, os quais são combinações de dois ou mais métodos de IA, também mostraram bons resultados.

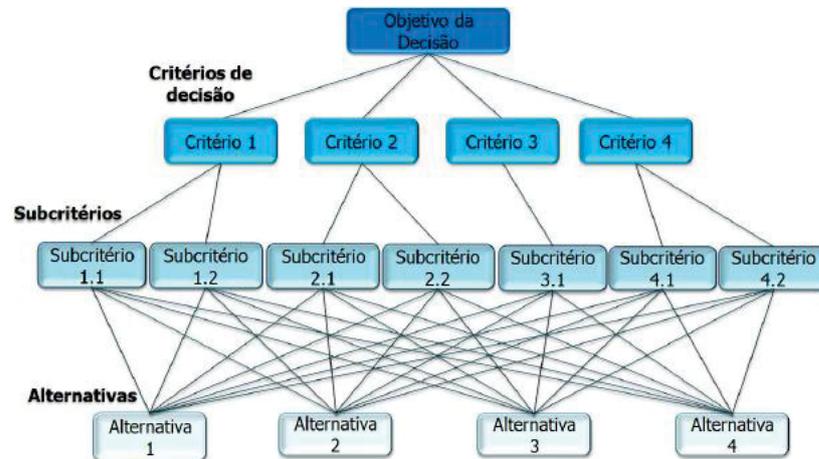
3 MÉTODO FUZZY AHP

3.1 ANALYTIC HIERARCHY PROCESS – AHP

O método *Analytic Hierarchy Process* – AHP é um método que auxilia na tomada de decisão com multicritério que foi desenvolvido por Thomas Saaty na década de 70. Segundo Saaty (2008), para que uma decisão possa ser tomada é necessário conhecer o problema, a necessidade e o propósito da decisão, conhecer os seus critérios e subcritérios, quais as partes interessadas, os grupos afetados e as ações alternativas. Para então determinar prioridades para que as alternativas se aloquem adequadamente aos recursos. Desta forma, Saaty (2008) reúne etapas que decompõem a decisão de maneira a gerar as prioridades. Essas etapas consistem em definir o problema e determinar o tipo de conhecimento que está sendo procurado; estruturar uma hierarquia de decisão, iniciando com o objetivo da decisão, seguido dos objetivos de uma forma mais ampla, após os critérios e por fim as alternativas; construir uma matriz comparando cada par de elementos de um nível superior com um elemento do nível imediatamente abaixo; e na última etapa usar as prioridades obtidas anteriormente para ponderar as prioridades no nível imediatamente abaixo, fazendo isso para cada elemento, e após isso adicionar os valores ponderados obtendo sua prioridade geral ou global e esse processo deve ser continuado até as prioridades finais das alternativas.

Saaty (1990) menciona que no Processo Analítico Hierárquico, os fatores são organizados em uma estrutura hierárquica iniciando com o objetivo geral, seguido de critérios, subcritérios e terminando em alternativas, como mostra a FIGURA 1.

FIGURA 1 - HIERARQUIA DO MÉTODO AHP



Fonte: Lima Junior (2013).

3.2 CONJUNTO FUZZY

Para explicar a ideia de conjunto fuzzy, Klir e Folger (1988) distinguem o conjunto *crisp* do conjunto fuzzy. Segundo os autores, *crisp* é o conjunto clássico, ou seja, aquele que apresenta uma dicotomia, onde um elemento pode pertencer ou não a um determinado conjunto. Mas, os autores mencionam que em algumas situações, a transição entre um elemento pertencer ou não a um conjunto é mais gradual e não tão abrupta como no conjunto *crisp*. Eles mencionam como exemplos o conjunto de pessoas altas, de carros caros, de doenças altamente contagiosas, de dias ensolarados, entre outros. Por isso, desejando eliminar um limite nítido (*sharp boundary*) para dividir membros e não membros, o conjunto fuzzy é apresentado. No conjunto fuzzy um elemento recebe um grau de pertencimento num intervalo de 0 a 1, de acordo com o grau de semelhança ou compatibilidade com o conjunto, levando em consideração se o elemento apresenta graus baixos ou altos de pertencimento. Com isso, o conjunto fuzzy busca introduzir imprecisão para eliminar a complexidade e reduzir o limite nítido de que um elemento pertença ou não a um conjunto. Assim, no conjunto fuzzy é possível dizer, por exemplo, que o dia está um pouco ensolarado, um pouco nublado, muito nublado, etc. Dessa forma, o conjunto fuzzy é uma generalização do conjunto *crisp*, ou ainda, o conjunto *crisp* é um caso particular de conjunto fuzzy, onde só é permitido os graus de pertencimento 0 ou 1 (KLIR, FOLGER, 1988).

Klir e Folger (1988) mencionam que o grau de pertencimento de um elemento ao conjunto fuzzy é determinado por uma função de pertinência μ_A (*membership function*) definida por

$$\mu_A: X \rightarrow [0,1],$$

Onde, X representa um conjunto universal, A um conjunto fuzzy e $[0,1]$ o intervalo de números reais de 0 a 1.

Zadeh (1965) apresenta algumas propriedades e implicações do conjunto fuzzy. De acordo o autor, o conjunto fuzzy é mais geral do que um conjunto comum, pode ter um escopo mais amplo para aplicabilidade e neste conjunto é possível lidar com a ideia de graus pertencimento a uma determinada classe. Zadeh (1965) propõe uma definição para um conjunto fuzzy:

Seja X um espaço de pontos (objetos), com um elemento genérico de X denotado por x . Assim, $X = \{x\}$.

Um conjunto fuzzy (classe) A em X é caracterizado por uma função de pertinência (característica) $f_A(X)$ que associa a cada ponto em X um número real no intervalo $[0,1]$, com o valor de $f_A(X)$ em x representando o "grau de pertinência" de x em A . Assim, quanto mais próximo o valor de $f_A(X)$ da unidade, maior o grau de pertinência de x em A . Quando A é um conjunto no sentido comum do termo, sua função de pertinência pode assumir apenas dois valores 0 e 1, com $f_A(X) = 1$ ou 0 conforme x pertence ou não a A . Assim, neste caso, $f_A(X)$ se reduz à função característica familiar de um conjunto A .

3.3 MÉTODO FUZZY ANALYTIC HIERARCHY PROCESS - FAHP

Ao combinar o método AHP de Saaty com a teoria de conjuntos Fuzzy de Zadeh (1965), tem-se o Fuzzy AHP (FAHP). Chang (1996) propõe uma abordagem de resolução para o FAHP denominada de método de análise de extensão (*extent analysis method*), a qual será utilizada neste trabalho. Desta forma, inicialmente serão apresentadas algumas definições importantes propostas por Chang (1996) e após isso os passos do método proposto por ele.

A primeira definição proposta por Chang (1996) é a de número fuzzy e a segunda a de número triangular fuzzy.

Definição 1. Seja $M \in F(\mathbb{R})$ chamado de número fuzzy se:

1) existe $x_0 \in R$ tal que $\mu_M(x_0) = 1$.

2) Para qualquer $\alpha \in [0,1]$,

$$A_\alpha = [x, \mu_{A_\alpha}(x) \geq \alpha]$$

é um intervalo fechado. Aqui $F(\mathbb{R})$ representa todos os conjuntos fuzzy, e \mathbb{R} é o conjunto dos números reais.

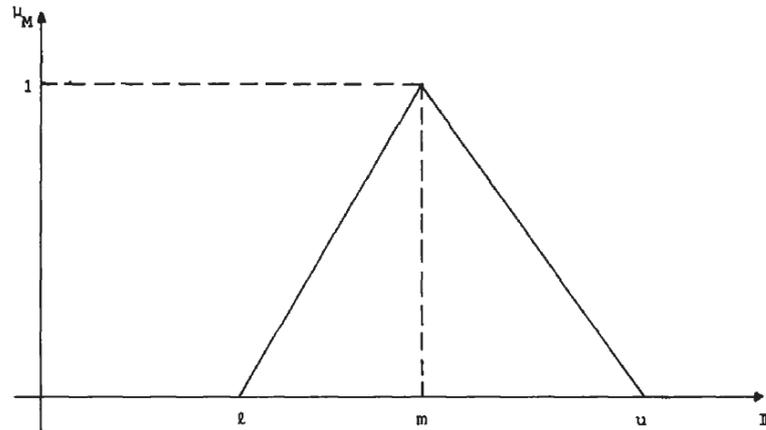
Definição 2. Um número fuzzy M em \mathbb{R} é definido como um número fuzzy triangular se sua função de pertinência $\mu_M(x): \mathbb{R} \rightarrow [0,1]$ é igual a

$$\mu_M(x) = \left\{ \begin{array}{ll} \frac{x}{m-l} - \frac{l}{m-l}, & x \in [l, m], \\ \frac{x}{m-u} - \frac{u}{m-u}, & x \in [m, u], \\ 0, & \text{caso contrário} \end{array} \right\} \quad (1)$$

Onde $l \leq m \leq u$. Temos que l e u representam o valor inferior e superior do suporte de M respectivamente, e m o valor modal.

Desta forma, o número fuzzy triangular pode ser denotado por (l, m, u) e o suporte de M é o conjunto de elementos $\{x \in \mathbb{R} \mid l < x < u\}$. Quando temos $l = m = u$, é considerado um número não fuzzy por convenção (CHANG, 1996). A FIGURA 2 apresenta uma função de pertinência μ_M de um número fuzzy triangular $M = (l, m, u)$.

FIGURA 2 - FUNÇÃO DE PERTINÊNCIA DE UM NÚMERO FUZZY TRIANGULAR



FONTE: Laarhoven; Pedrycz (1983).

Chang (1996) também apresenta as leis operacionais entre os números triangulares, soma, multiplicação, multiplicação por escalar e inverso, como descritas abaixo:

Considere dois números fuzzy triangulares M_1 e M_2 , $M_1 = (l_1, m_1, u_1)$ e $M_2 = (l_2, m_2, u_2)$. Suas leis operacionais são as seguintes:

$$1. (l_1, m_1, u_1) \oplus (l_2, m_2, u_2) = (l_1 + l_2, m_1 + m_2, u_1 + u_2) \quad (2)$$

$$2. (l_1, m_1, u_1) \odot (l_2, m_2, u_2) = (l_1 l_2, m_1 m_2, u_1 u_2) \quad (3)$$

$$3. (\lambda, \lambda, \lambda) \odot (l_1, m_1, u_1) = (\lambda l_1, \lambda m_1, \lambda u_1), \lambda > 0, \lambda \in \mathbb{R}. \quad (4)$$

$$4. (l_1, m_1, u_1)^{-1} = \left(\frac{1}{u_1}, \frac{1}{m_1}, \frac{1}{l_1} \right) \quad (5)$$

Agora serão apresentados os passos para a resolução de prioridades de critérios com o método FAHP proposto por Chang (1996). Assim, considerando as matrizes R_1, R_2, \dots, R_k de comparação par a par, respondida por k participantes, e dados os m critérios C_1, C_2, \dots, C_m . Sendo, as R_k dada por:

$$R_k = \begin{bmatrix} (1,1,1) & (l_{12}, m_{12}, u_{12}) & \dots & (l_{1m}, m_{1m}, u_{1m}) \\ (l_{21}, m_{21}, u_{21}) & (1,1,1) & \dots & (l_{2m}, m_{2m}, u_{2m}) \\ \vdots & \vdots & \ddots & \vdots \\ (l_{n1}, m_{n1}, u_{n1}) & (l_{n2}, m_{n2}, u_{n2}) & \dots & (1,1,1) \end{bmatrix}$$

1º passo: Calcular a média dos números triangulares em cada comparação par a par dos critérios nas k matrizes R_k , obtendo uma matriz R ;

2º passo: Utilizando a matriz R , calcular a extensão sintética fuzzy de cada $i = 1, 2, \dots, n$, dada pela fórmula:

$$S_i = \sum_{j=1}^m M_{g_i}^j \odot \left[\sum_{i=1}^n \sum_{j=1}^m M_{g_i}^j \right]^{-1} \quad (6)$$

Onde todos os $M_{g_i}^j$ ($j = 1, 2, \dots, m$) são números fuzzy triangulares.

3º passo: Aplicar o princípio da comparação de números fuzzy, comparando todos M_i , ($i = 1, 2, \dots, k$), sendo eles números fuzzy convexos (CHANG, 1996; LIMA JUNIOR, 2013).

$$V(M_1 \geq M_2) = 1 \text{ iff } m_1 \geq m_2 \quad (7)$$

$$V(M_2 \geq M_1) = 0 \text{ iff } l_1 \geq u_2 \quad (8)$$

$$V(M_2 \geq M_1) = \frac{l_1 - u_2}{(m_2 - u_2) - (m_1 - l_1)} \quad (9)$$

4º passo: Calcular os pesos em relação a cada elemento sob um determinado critério, com a fórmula:

$$d'(C_i) = \min V(S_i \geq S_k), \quad k = 1, \dots, n, \quad k \neq i. \quad (10)$$

5º passo: O vetor dos pesos é dado por:

$$W' = (d'(C_1), d'(C_2), \dots, d'(C_n))^T \quad (11)$$

Sendo C_i ($i = 1, 2, \dots, n$) n elementos.

6º passo: Normalizar W' :

$$W = (d(C_1), d(C_2), \dots, d(C_n))^T \quad (12)$$

Desta forma, W é um número não fuzzy.

7º passo: Normalizar a matriz dos candidatos e calcular a média ponderada com os pesos obtidos.

8º passo: Somar os elementos das colunas de cada linha, obtendo o vetor de prioridades, com a prioridade de cada paciente considerado na linha da matriz de prioridades.

4 REDES NEURAIS ARTIFICIAIS

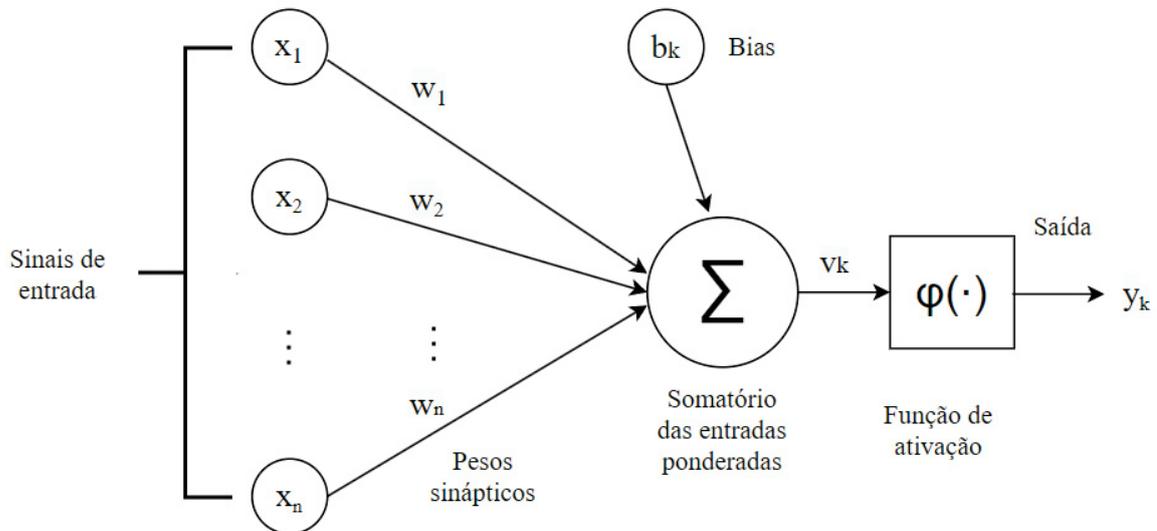
De acordo com Nielsen (2015), redes neurais são métodos de inteligência artificial inspirados no funcionamento do cérebro humano e seus neurônios. Segundo o autor, uma rede neural aprende com a observação de dados de um problema e promove uma solução. A partir de 2006, com as redes neurais profundas (*deep learning*) já era possível superar os resultados de abordagens mais tradicionais, alcançando desempenhos excepcionais.

Dessa forma, o processo de uma rede neural consiste em tomar um conjunto de elementos de entradas, aplicar pesos a esses valores, para obter uma resposta correta referente aos dados de entrada. Nesse processo, a rede aprende a obter os melhores pesos para encontrar essa resposta, realizando processos de atualização dos pesos. Nesse capítulo será apresentado, brevemente, o funcionamento de uma rede neural, os seus elementos e conceitos principais, de acordo com Haykin (2009), Silva, Spatti e Flauzino (2016) e Nielsen (2015).

4.1 PERCEPTRON DE UMA CAMADA

O *perceptron* de uma camada é a estrutura mais básica de uma rede neural. Ele é composto por neurônios, conjuntos de sinapses, bias, somatório, função de ativação. Abaixo, serão descritos esses elementos que compõem uma rede neural e a FIGURA 3 mostra um esquema da formação desses elementos na rede neural.

FIGURA 3 – ESQUEMA DO PERCEPTRON DE UMA CAMADA



Fonte: A autora (2024) adaptado de Haykin (2009).

Neurônios: são unidades de processamento de informações.

Entradas: são os neurônios da primeira camada, onde cada neurônio representa uma característica. São identificados por $(x_1, x_2, x_3, \dots, x_m)$.

Conjuntos de sinapses: são conexões ponderadas entre os neurônios da entrada e o da saída (em redes neurais com várias camadas, essas sinapses conectam os neurônios de uma camada com a próxima camada). Os pesos são identificados por $(w_1, w_2, w_3, \dots, w_m)$.

Bias: São neurônios adicionais inseridos na estrutura da rede neural, os quais tem o efeito de aumentar ou diminuir a entrada líquida (valor resultante das entradas ponderadas). O acréscimo de bias pode apresentar valores de saída diferentes, mesmo que todas as entradas tenham valor zero. Os *bias* são identificados por b_k .

Função soma: É dada pelo somatório das multiplicações dos valores das entradas (x_j) , pelos valores dos pesos (w_j) , ou seja:

$$\sum_{j=1}^m w_j \cdot x_j$$

Função de ativação ($\varphi(x)$): o valor encontrado no somatório é aplicado nessa função. Existem várias funções de ativação, dentre as mais comuns está a *step function* e a *sigmoide*. Serão descritas também, as outras funções de ativação utilizadas nesse trabalho: *Softmax*, *Relu*, *Elu* e *Leaky Relu*.

A “*step function*” atribui o valor 1, se o resultado encontrado no somatório for maior ou igual a zero e atribui o valor 0, se o resultado for menor que zero. Ou seja,

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

A *sigmoide* é uma função que retorna valores entre 0 e 1, retornando um valor próximo de zero, quanto menor for o valor de x e valores próximos de um, quanto maior for o valor de x . Assim, a sigmoide é dada pela fórmula:

$$\varphi(x) = \frac{1}{1 + e^{-x}}$$

A *Softmax*, é utilizada em classificação multiclases e produz valores no intervalo [0, 1] e sua soma é igual a 1. Assim, dado um vetor $z = [z_1, z_2, \dots, z_n]$,

$$\varphi(z_i) = \frac{e^{z_i}}{\sum_{j=1}^n e^{z_j}}$$

A *Relu* é dada por:

$$\varphi(x) = \max(0, x)$$

Ou seja, se a entrada é positiva, a função retorna o próprio valor x , se for negativa, retorna 0.

A *Elu* é dada por:

$$\varphi(x) = \begin{cases} x & \text{se } x > 0 \\ \alpha (e^x - 1) & \text{se } x \leq 0 \end{cases}$$

Sendo α um hiperparâmetro.

A *Leaky Relu*:

$$\varphi(x) = \begin{cases} x & \text{se } x > 0 \\ \alpha x & \text{se } x \leq 0 \end{cases}$$

Sendo α um hiperparâmetro, pequeno e positivo.

Dessa forma, dadas as entradas e os pesos, o cálculo do valor da saída da rede neural é realizado da seguinte maneira:

Inicialmente é feito o somatório de todas as entradas multiplicadas pelos respectivos pesos, obtendo u_k :

$$u = \sum_{j=1}^m w_j \cdot x_j$$

Após isso, soma-se o *bias* ao valor obtido:

$$v = u + b$$

Por fim, aplica-se esse resultado na função ativação, obtendo a saída y da rede neural.

$$y = \varphi(v)$$

4.2 ERRO

A saída obtida anteriormente é comparada com a resposta correta para os dados de entrada utilizados, obtendo-se um erro para a resposta dada pela rede neural. Dessa forma, a maneira mais simples para calcular esse erro é obter a distância entre a resposta correta (valor observado) e a resposta calculada (valor predito). Então, a fórmula do erro pode ser dada por:

erro = valor observado – valor predito.

Após isso, obtém-se a média absoluta dos erros encontrados.

Outros erros também são utilizados para calcular a distância entre essas respostas, dentre eles estão o *Mean Square Error* (MSE) e o *Root Mean Square Error* (RMSE). Para calcular o MSE, as distâncias são elevadas ao quadrado e então, calculada a média absoluta. Para calcular o RMSE, basta extrair a raiz quadrada o valor obtido no MSE. Esses dois exemplos são interessantes, pois penalizam mais o erro, elevando a distância entre as respostas ao quadrado. Suas fórmulas são dadas a seguir:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y - \hat{y})^2$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y - \hat{y})^2}$$

Outros erros, os quais foram utilizados nesse trabalho, são descritos a seguir:

Categorical Crossentropy (CC):

$$CC = - \sum_{i=1}^n y_i \log(\hat{y}_i)$$

Binary Crossentropy (BC):

$$BC = -[y \log(\hat{y}) + (1 - y) \log(1 - \hat{y})]$$

Sendo:

n : número de amostras

y : valor observado

\hat{y} : valor predito

4.3 ATUALIZAÇÃO DOS PESOS

O processo de aprendizagem numa rede neural consiste em realizar a atualização dos pesos para que o erro seja o menor possível. Dessa forma, ao finalizar um processo encontrando a saída e o erro, é necessário realizar uma mudança nos pesos, visando encontrar melhores resultados. Assim, o peso atualizado será dado por:

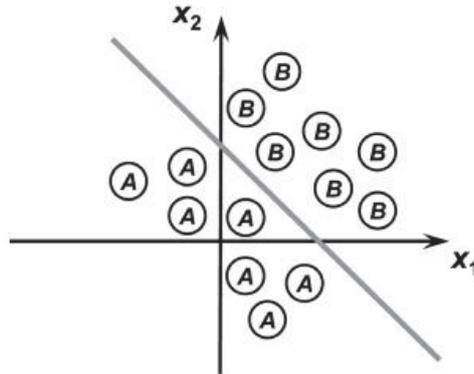
$$peso(n + 1) = peso(n) + (taxa\ de\ aprendizagem \cdot entrada \cdot erro)$$

Então, o peso atualizado é a soma do peso anterior com multiplicação entre a taxa de aprendizagem, a entrada e o erro. A taxa de aprendizagem é um parâmetro que serve para acelerar o ajuste dos pesos.

4.4 REDES MULTICAMADAS

O *perceptron* de uma camada é útil para resolver problemas linearmente separáveis, ou seja, quando é possível separar linearmente classes de respostas. A FIGURA 4 apresenta um exemplo de uma rede neural com duas entradas (x_1, x_2), e com duas possibilidades de resposta, sendo as duas classes de resposta separadas por uma reta.

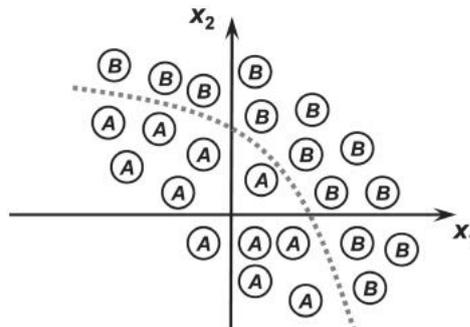
FIGURA 4 – EXEMPLO DE PROBLEMA LINEARMENTE SEPARÁVEL



FONTE: Silva, Flauzino e Andrade (2010).

Por outro lado, se o problema for não linearmente separável, não será possível separar o problema em duas classes utilizando uma única reta, como mostra a FIGURA 5.

FIGURA 5 – EXEMPLO DE PROBLEMA NÃO LINEARMENTE SEPARÁVEL

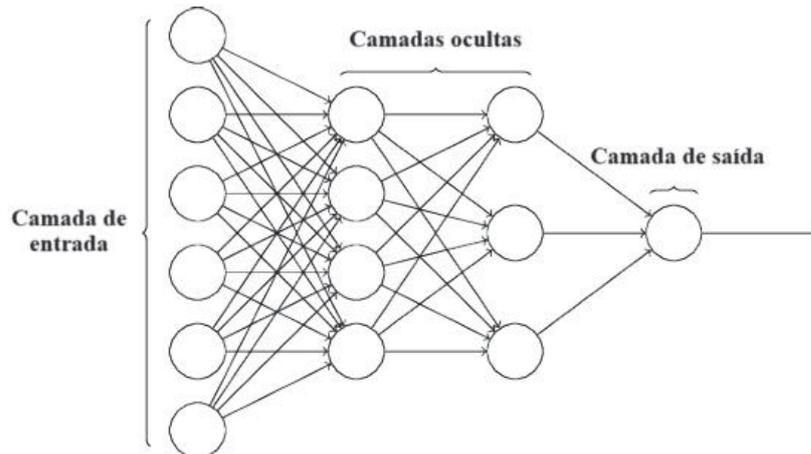


FONTE: Silva, Flauzino e Andrade (2010).

Portanto, para esse tipo de problema (não linearmente separável) e para problemas mais complexos, utiliza-se as redes neurais multicamadas. Nessa estrutura de rede, há pelo menos uma camada intermediária de neurônios (camadas ocultas) entre a camada de entrada e de saída. Dessa forma, cada camada receberá informações da camada anterior, fluindo em uma única direção da camada de entrada, passando pelas camadas ocultas, até a camada de saída (rede *feedforward*). Nas redes multicamadas o processo de cálculos é semelhante ao *perceptron* de uma camada. Nesse caso, os valores dos neurônios de entrada são submetidos ao cálculo do somatório e da função de ativação, obtendo valores para a camada oculta. Da mesma forma, esse processo é feito de uma camada oculta para a outra, sempre na mesma direção, até chegar a camada de saída. A FIGURA 6 mostra um exemplo

desse processo, com seis neurônios na camada de entrada, duas camadas ocultas (uma com quatro neurônios e outra com três) e a camada de saída com um neurônio.

FIGURA 6 – EXEMPLO DE PERCEPTRON MULTICAMADAS



FONTE: Nielsen (2015).

4.5 DESCIDA DO GRADIENTE E BACKPROPAGATION

Após a realização do processo apresentado acima e a obtenção do resultado no neurônio de saída, calcula-se o erro da resposta dada pela rede neural comparada com a resposta observada. Se o erro for grande, é necessário fazer o ajuste dos pesos. O algoritmo *backpropagation* auxilia na busca por pesos que diminuam o erro, utilizando o conceito de gradiente. Esse algoritmo é aplicado atualizando os pesos da camada de saída para a última camada oculta, da última camada oculta até a penúltima, até chegar na camada de entrada, ou seja, realiza o processo contrário, do final para o início. Esse processo completo, até o final da atualização dos pesos é denominado de época. Dessa forma, para o treinamento da rede é realizada uma certa quantidade de épocas, visando obter respostas com os menores erros possíveis, para que ao realizar as previsões, o modelo de rede neural apresente um bom desempenho, prevendo as respostas com o menor número de erros possível.

5 METODOLOGIA

Neste capítulo será definida a metodologia para resolver o problema de priorização de pacientes em conjunto com a utilização de redes neurais. Dessa forma, primeiramente, a metodologia apresenta o processo de priorização de pacientes com o FAHP, utilizando os problemas da COVID-19 e da cirurgia de NLPC. Após isso, apresenta também, a abordagem de redes neurais em conjunto com o processo de priorização, seguindo as ideias de técnicas *ensemble*. A abordagem de redes neurais utiliza somente o problema da cirurgia de NLPC, a qual tem como resposta os pesos dos critérios obtidos no FAHP. Então, para detalhar o processo de priorização de pacientes, a FIGURA 7 apresenta um esquema com as cinco etapas desse processo e ao longo do capítulo, serão detalhadas e descritas cada uma dessas etapas. Por fim, será descrita a abordagem de redes neurais proposta, após esse processo de priorização.

FIGURA 7 - FLUXOGRAMA DAS ETAPAS DA PRIORIZAÇÃO



FONTE: A autora (2024).

5.1 DEFINIÇÃO DOS OBJETIVOS DO ESTUDO

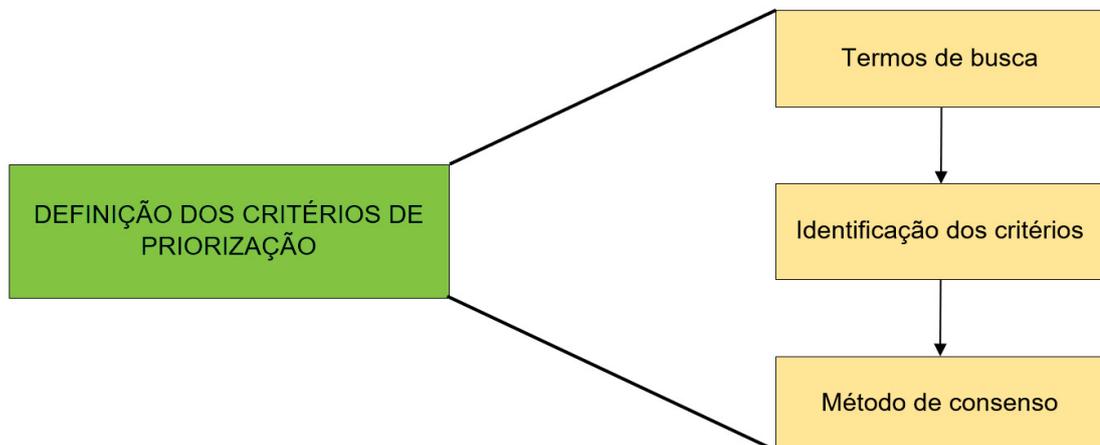
A primeira etapa do processo de priorização se trata da definição dos objetivos do estudo. Então, o problema em questão nesse trabalho se trata de priorizar pacientes que necessitem de algum atendimento hospitalar e que por motivos de superlotação, falta de recursos, dentre outros, gere uma longa fila de espera, na qual a equipe de saúde necessite decidir qual paciente deve ter a prioridade no atendimento. A priorização desses pacientes deve ser feita por meio do método Fuzzy AHP e com o auxílio da opinião de especialistas. Desta forma, os objetivos deste estudo são determinados e consistem na identificação dos critérios de gravidade que os pacientes possam apresentar para a realização do atendimento, o cálculo dos

pesos dos critérios, a coleta de dados dos pacientes e o cálculo do escore dos pacientes.

5.2 DEFINIÇÃO DOS CRITÉRIOS DE PRIORIZAÇÃO

De acordo com a segunda etapa, a escolha dos critérios de priorização pode ser feita com uma revisão na literatura, seguindo os passos apresentados na FIGURA 8. Dessa forma, dentro da etapa “definição dos critérios de priorização” estão as subetapas “termos de busca”, “identificação dos critérios” e “método de consenso”.

FIGURA 8 - PASSOS DA ETAPA DE DEFINIÇÃO DOS CRITÉRIOS DE PRIORIZAÇÃO



FONTE: A autora (2024).

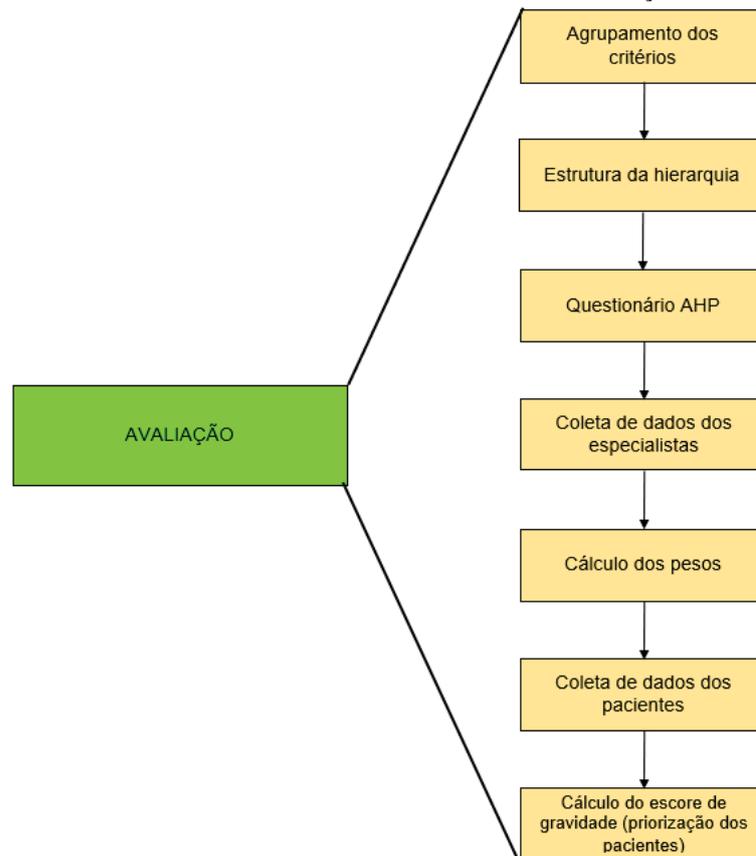
Inicialmente, os termos de busca referentes ao tema são definidos e procuram-se artigos em bases de pesquisa. Após isso, uma seleção desses artigos é feita e alguns artigos são eliminados pela leitura do título, outros pela leitura do resumo e por último, alguns são eliminados pela leitura na íntegra. Os artigos que restarem são utilizados para a identificação dos critérios de gravidade. Com os critérios já elencados, é possível utilizar um método de consenso, solicitando que especialistas definam níveis de importância de cada critério, o que pode ser feito com a utilização de um questionário, no qual os especialistas podem comparar os critérios e indicar os mais importantes. Com o método de consenso espera-se que haja uma convergência nas respostas, indicando os critérios de maior gravidade, dentre os critérios elencados na revisão bibliográfica.

Uma opção para o método de consenso é o Delphi, o qual, segundo Turoff e Listone (1975), pode ser utilizado para estruturar um processo de comunicação em grupo. Desta forma, essa comunicação estruturada resulta em feedbacks das contribuições, conhecimentos individuais, avaliações de julgamento e ponto de vista do grupo, mantendo o anonimato dos participantes. Segundo Wright e Giovinazzo (2000) o Método Delphi visa estruturar o conhecimento, a experiência e a criatividade de especialistas de um determinado assunto. Segundo eles, o julgamento coletivo é melhor para se chegar a um consenso, do que a opinião de uma só pessoa. Assim, Wright e Giovinazzo (2000) mencionam que no método Delphi, um questionário circula entre um grupo de especialistas, em algumas rodadas, onde o anonimato dos participantes é mantido. Na primeira rodada, os especialistas respondem o questionário e as respostas quantitativas são tabuladas e passam por um tratamento estatístico. Depois os questionários são devolvidos para os especialistas, com os dados estatísticos e acontece mais uma rodada com a resposta dos especialistas, mas dessa vez eles conhecem as respostas dos demais respondentes. Esse processo é repetido até que seja obtido um consenso e convergência da opinião dos especialistas. Quando isso acontece, as rodadas se encerram.

5.3 AVALIAÇÃO

Após o processo de consenso dos especialistas sobre os critérios, inicia-se a terceira etapa, de avaliação. Nessa etapa, como apresentada na FIGURA 9, os critérios são agrupados e estruturados num formato de hierarquia, como proposto por Saaty (1990). Esse processo deve ser feito com a participação de pesquisadores da área da saúde, que conheçam os critérios e possam separá-los e estruturar a hierarquia. Dessa forma, dentro da etapa “avaliação” estão as subetapas “agrupamento dos critérios”, “estrutura da hierarquia”, “questionário AHP”, “coleta de dados dos especialistas”, “cálculo dos pesos”, “coleta de dados dos pacientes”, “cálculo do escore de gravidade (priorização dos pacientes)”.

FIGURA 9 – PASSOS DA ETAPA DE AVALIAÇÃO



FONTE: A autora (2024).

Após isso, é realizada uma entrevista com os especialistas, onde eles podem comparar, par a par, cada critério. Esse processo não necessariamente precisa ser quantitativo, os especialistas podem responder somente que um critério tem um nível de importância pequeno, grande ou muito grande em relação a outro critério. Então, esses julgamentos são transformados em números, de acordo com uma escala proposta por Saaty, e posteriormente, mudados para números triangulares Fuzzy, como será apresentado posteriormente.

Após a obtenção das matrizes contendo os números triangulares fuzzy, representando a opinião dos especialistas em relação a cada par de critérios, inicia-se o processo do cálculo dos pesos desses critérios. O método utilizado nesse trabalho foi o Fuzzy AHP, o qual também será detalhado posteriormente.

O próximo passo é realizar a coleta de dados dos pacientes reais, obtendo as informações desses pacientes em relação aos critérios que já foram priorizados. Em seguida, calcula-se o escore dos pacientes, obtendo uma média ponderada dos valores apresentados pelos pacientes em cada critério, com os pesos obtidos anteriormente.

5.4 VERIFICAÇÃO E VALIDAÇÃO

A quarta etapa se trata da verificação e da validação do processo. Dessa forma, com os pesos dos critérios calculados, há necessidade de uma verificação e uma validação desses pesos. O processo de verificação é feito com cálculos manuais de pelo menos um subcritério, para comparar os pesos dados pelo método com os pesos obtidos com o cálculo manual, com o fim de verificar se o método foi implementado corretamente. O processo de validação consiste em comparar as respostas do método com a opinião de pelo menos um especialista participante das entrevistas, a fim de analisar se as respostas do método são coerentes com a realidade de um ambiente na área da saúde.

5.5 IMPLEMENTAÇÃO

Após todas as etapas, deverá ser realizada uma implementação desse processo numa plataforma de priorização, que não está no escopo desse trabalho, mas será pensada para trabalhos futuros. A intenção é implementar o processo de priorização numa plataforma online, sendo possível a manipulação e utilização pela equipe de saúde, para priorizar pacientes que estejam em filas de espera de algum procedimento hospitalar. Com isso, é possível auxiliar a equipe de saúde a obter uma melhor utilização dos recursos hospitalares e a proporcionar bem-estar aos pacientes, pois o processo terá por objetivo priorizar os pacientes que mais necessitem do atendimento, proporcionando também, uma imparcialidade na escolha desses pacientes.

Pécora et al. (2021) também propõem uma implementação numa plataforma de priorização, a princípio para priorizar pacientes de uma fila de espera de 3000 pessoas, para a realização de um exame de urologia, mas que pode se adaptar a qualquer lista de espera do hospital. Os autores sugerem que o acesso seja para todo o pessoal envolvido na equipe de saúde, promovendo formação para a utilização da plataforma. Pécora et al. (2021) também mencionam a possibilidade de inclusão de novos pacientes, atualização diária da situação da fila, ajuste dos pesos dos critérios e da plataforma de modo geral.

5.6 ABORDAGEM DE REDES NEURAIIS

Ao final da etapa descrita anteriormente, será aplicada uma proposta de redes neurais em duas partes, utilizando como resposta o resultado da priorização de pacientes com o FAHP. Na primeira parte será construída uma rede neural que classifica os pacientes da fila de espera em três grupos de prioridade e na segunda parte, em cada um desses grupos será realizada uma priorização dos pacientes. Após isso, serão realizados experimentos computacionais, variando alguns parâmetros, para verificar o desempenho das redes propostas.

Essa abordagem permitirá uma mudança dinâmica da posição dos pacientes, sempre que necessário, além de fazer previsões da classificação e da prioridade de supostos pacientes que forem incluídos nessa fila de espera.

6 PROCESSO DE PRIORIZAÇÃO DE PACIENTES COM FAHP

Este capítulo abordará um exemplo de processo de priorização de pacientes utilizando o método FAHP, de acordo com a metodologia apresentada, ou seja, abordará as etapas de definição dos objetivos do estudo, definição dos critérios de priorização, avaliação, verificação e validação e implementação. Para isso, serão utilizados dois problemas, priorização de pacientes com COVID-19 e priorização de pacientes na fila de espera para a realização da cirurgia de NLPC.

6.1 DEFINIÇÃO DOS OBJETIVOS DO ESTUDO

6.1.1 Covid-19

No processo de priorização a ser descrito, a definição dos critérios será exemplificada pelo problema do COVID-19, as etapas de avaliação, verificação e validação serão exemplificadas pelo problema da cirurgia de Nefrolitotripsia Percutânea.

O problema de priorização de pacientes com COVID-19 surgiu devido à pandemia do novo coronavírus. Durante a pandemia, hospitais e postos de saúde de todo o mundo sofreram com a alta demanda de pacientes portadores da COVID-19, gerando superlotação para internação em enfermarias e UTI's. Com isso, surgiram filas de espera para internação desses pacientes, levando os profissionais da saúde a decidirem qual paciente deveria ter prioridade para receber um leito de enfermaria ou UTI, para serem tratados dessa doença. Diante disso, o primeiro problema em questão nesse trabalho se trata de priorizar pacientes com COVID-19 que necessitem de hospitalização.

6.1.2 NLPC

O segundo problema se trata de priorizar pacientes na fila de espera eletiva para a realização de uma cirurgia, indicada para tratamento de litíases urinárias (cálculos renais), no Complexo Hospital de Clínicas de Curitiba (CHC). Pigatto Filho

et al. (no prelo) mencionam que, a NLPC é um tratamento padrão ouro para cálculos renais maiores que 2 centímetros. Até para cálculos menores do que a recomendação padrão, geralmente a única opção viável acaba sendo a NLPC. Por outro lado, a NLPC necessita de materiais específicos, profissionais com formação acadêmica especializada, suporte multidisciplinar e retaguarda em caso de necessidade de Unidade de Terapia Intensiva (UTI) ou Serviço de Hemodinâmica, sendo esses recursos insuficientes e escassos no SUS brasileiro (TOSTES, 2016; ASTOLFI, 2020). Diante desse quadro, atualmente 385 pacientes, aproximadamente, estão aguardando cirurgia, com um tempo de espera que pode chegar a 6 anos. Na fila de espera existem pacientes de vários níveis de gravidade da doença, de casos mais simples até casos mais graves. Os casos graves podem ocasionar complicações por conta do atraso no atendimento, como por exemplo, insuficiência renal crônica, sepse urinária, infecções graves, perda de parte da função dos rins, dentre outras. Alguns pacientes acabam falecendo devido a falta de tratamento de maneira adequada (KUKREJA, 2003).

6.2 DEFINIÇÃO DOS CRITÉRIOS DE PRIORIZAÇÃO

6.2.1 Covid-19

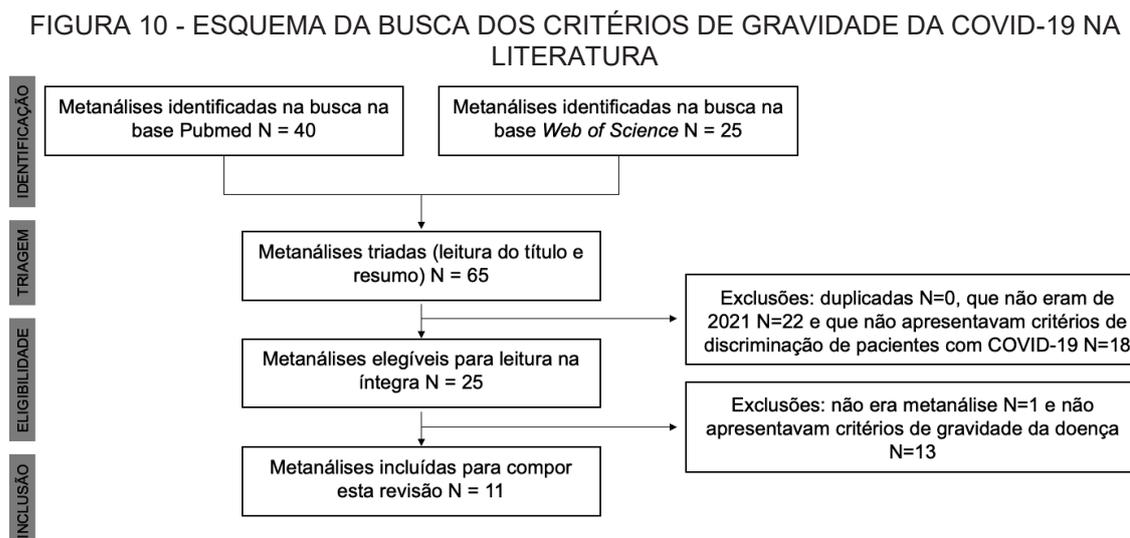
A segunda etapa se trata da definição dos critérios para priorização. Assim, para definir os critérios, foi realizada uma revisão de escopo, buscando na literatura os critérios que os pacientes com gravidade da COVID-19 apresentaram. Da busca na literatura, foram selecionados onze artigos para identificar os critérios e 72 critérios foram retirados desses artigos. Além disso, esses 72 critérios foram separados em cinco categorias (demográfico, comorbidade, laboratorial, clínico e radiologia).

6.2.1.1 Termos de busca

Para determinar os critérios, os quais serão utilizados nos métodos de priorização, foi realizada uma revisão de escopo, de acordo com Tricco et al. (2018). Nesta revisão foram identificados critérios de gravidade de pacientes internados com COVID-19. A busca foi realizada nas bases de dados “*PubMed*” e “*Web of Science*”. Na *PubMed* utilizou-se os termos “*covid hospitalization criteria*”, com seleção dos

filtros para metanálise e o ano de 2021. Na base de dados *Web of Science* foi utilizada a seguinte string: TS = ("corona virus" OR COVID OR COVID-19 or "SARS-CoV-2" OR "coronavirus" OR "COVID 19" OR "nCoV " OR "2019-nCov") AND ("Hospitalization criteria" OR "Admission Criteria" OR "Patient Selection" OR "Criteria, Selection" OR "Patient Selections" OR "Selection Criteria" OR "Selection for Treatment" OR "Selection for Treatments" OR "Selection, Patient" OR "Selections, Patient" OR "Treatment, Selection for" OR "Treatments, Selection for" OR "Patient Admission" OR "Admission, Patient" OR "Admissions, Patient" OR "Patient Admissions") AND (meta-analysis OR "meta analysis").

Foram escolhidos somente artigos que se tratavam de metanálises, que apresentavam critérios mais frequentes em pacientes hospitalizados por conta da COVID-19 ou critérios que tinham alguma associação com a gravidade da doença. Os artigos de 2020 foram descartados, devido à evolução das descobertas sobre a doença. Desta forma, foram incluídos somente artigos do ano de 2021. A busca e seleção dos artigos foram realizadas por dois pesquisadores individualmente, sem compartilhar os resultados e um terceiro pesquisador verificou a seleção. Desta forma, foram incluídos na revisão, os artigos que foram selecionados pelos dois primeiros pesquisadores. Na FIGURA 10 estão os processos realizados para a determinação dos artigos.



FONTE: A autora (2022).

6.2.1.2 Identificação dos critérios

Os onze artigos selecionados foram lidos na íntegra e retirados todos os critérios encontrados que se referiam a gravidade da COVID-19. Foram encontrados 88 critérios, os quais foram analisados pelos pesquisadores da área da saúde participantes do projeto. Eles excluíram os critérios que apresentaram evidências fracas, que já são associados com a gravidade da doença, que foram considerados critérios de confusão, que não estavam disponíveis na realidade dos pesquisadores e do ambiente da pesquisa ou que se tratava de critérios apresentados em decorrência do internamento do paciente e não da doença. Após isso, eles realizaram uma separação dos critérios em cinco categorias (demográfico, comorbidade, laboratorial, clínico e radiologia). Desta forma, ao final da revisão, foram determinados 60 critérios de gravidade da COVID-19, os quais estão apresentados no QUADRO 3.

QUADRO 3 - CRITÉRIOS DETERMINADOS PELA REVISÃO NA LITERATURA

Demográfico	1. Idade
	2. Sexo
Comorbidades	3. Imunossupressão ou quimioterapia
	4. Câncer
	5. Diabetes
	6. Hipertensão
	7. Doença renal crônica
	8. Terapia de substituição renal contínua
	9. Malignidade
	10. Doença cerebrovascular
	11. Insuficiência cardíaca
	12. Doença cardiovascular
	13. Tabagismo
	14. Arritmia
	15. Doença pulmonar crônica
	16. Gestação
	17. Presença de comorbidade (sim; não)
	18. Número de comorbidades
Laboratorial	19. Contagem de leucócitos
	20. Contagem de linfócitos
	21. Contagem de plaquetas
	22. Creatinina
	23. Ureia
	24. Proteína C reativa
	25. Ferritina
	26. Lactato desidrogenase

	27. Tempo de protrombina (RNI)
	28. Fibrinogênio
	29. Troponina
	30. D-dímero
	31. AST
	32. ALT
	33. Albumina
	34. Bilirrubina total
Clínico	35. Disfunção orgânica
	36. Choque
	37. Choque refratário
	38. Tempo desde o início da doença até a primeira admissão hospitalar
	39. IMC
	40. Lesão renal aguda
	41. SOFA
	42. APACHE
	43. SRAG (dispneia/desconforto respiratório OU pressão persistente no tórax OU saturação de O ₂ menor que 95% em ar ambiente OU coloração azulada dos lábios ou rosto)
	44. SARA / SDRA (definição de Berlin)
	45. Saturação de oxigênio em repouso (ar ambiente)
	46. Relação gasométrica (PaO ₂ / FiO ₂)
	47. Insuficiência respiratória que requer ventilação mecânica
	48. Saturação de oxigênio (O ₂) ≤ 93%
49. Dificuldade respiratória com frequência respiratória (RR) ≥ 30	
50. Evento de tromboembolismo venoso	
51. Oxigenação não invasiva	
Radiologia	52. Bronquiectasia de tração
	53. consolidação
	54. Reticulação
	55. Infiltrados bilaterais
	56. Opacidades em vidro fosco (<i>ground glass opacities</i>)
	57. Espessamento de septos interlobulares
	58.. Derrame pleural na tomografia*
	59. anomalias na tomografia afetando apenas um lobo*
	60. Pneumonia unilateral*

FONTE: A autora (2022).

6.2.1.3 Método de consenso

Após a seleção e categorização dos 60 critérios, um método de consenso é utilizado para reduzir essa quantidade de critérios, para que seja viável realizar a

priorização dos pacientes com COVID-19. Neste trabalho o método utilizado para o consenso foi o Delphi. Dessa forma, a ideia geral é obter um consenso desses especialistas sobre quais são os critérios mais importantes na determinação da gravidade da COVID-19.

Então, para a aplicação do Delphi, um questionário foi desenvolvido na plataforma *qualtrics*, podendo ser respondido online. Esse questionário contém uma breve apresentação da priorização a ser realizada, a identificação dos participantes, o local da realização da pesquisa, informações e explicações sobre o questionário, possui também um campo para inserção do nome e um campo para a inserção do e-mail do respondente. Além de um termo de consentimento livre e esclarecido e as perguntas em questão. O questionário está organizado da seguinte forma, possui 12 questões com cinco critérios cada e em cada critério o respondente deverá mover um cursor indicando uma importância para aquele critério, com um valor de 0 a 100. No final das questões há um campo para o respondente acrescentar algum comentário ou critério, se achar pertinente. Não é obrigatório preencher esse campo. O questionário pode ser respondido em aproximadamente 20 min e os critérios foram dispostos em ordem aleatória. O questionário traz no final 7 questões de caráter pessoal para os respondentes, como por exemplo, sexo, idade, formação, dentre outras. Em cada critério há uma breve descrição do que ele se trata, basta mover o cursor para cima do critério que essa descrição aparecerá.

O questionário foi aplicado aos especialistas e esperava-se um número de 15-20 respondentes, mas essa fase ainda está para ser concluída e não pertence ao escopo deste trabalho. A pretensão é de realizar três rodadas do método Delphi, ou seja, recolher a primeira rodada de respostas desses especialistas, após isso, realizar análises estatísticas e verificar se houve um consenso dos principais critérios, se não houve, aplica-se o questionário novamente e repete o processo até obter um consenso dos principais critérios dentre os 60 obtidos.

Os estudo sobre o Covid-19 encerrou durante a etapa da aplicação do método Delphi, devido à redução da preocupação com a doença e o fim das filas de espera para a ocupação de leitos. Dessa forma, nas outras etapas desse trabalho será utilizada somente o problema da NLPC.

6.2.2 NLPC

Essas etapas não foram detalhadas nesse trabalho para o problema de NLPC, pois foram realizadas por Pigatto Filho et al. (no prelo). Desta forma, os critérios utilizados sobre a NLPC foram selecionados como descrito pelos autores.

6.3 AVALIAÇÃO

Este capítulo descreverá o processo de organização e coleta de dados dos critérios, para o cálculo dos pesos com o método FAHP. As etapas de agrupamento dos critérios, estruturação da hierarquia, questionário AHP, coleta de dados dos especialistas e cálculo dos pesos foram descritas considerando o problema da NLPC. A partir dessa etapa, não será mais utilizado o problema do Covid-19.

6.3.1 Agrupamento dos critérios

A partir de uma revisão da literatura sobre critérios de gravidade em litíase urinária e sobre as principais adversidades encontradas no manejo rotineiro com a fila cirúrgica eletiva, Pigatto Filho et al. (no prelo), selecionaram quatro critérios de gravidade para a cirurgia, dentre eles, um critério possui dois subcritérios. Esses critérios e subcritérios serão utilizados nesse trabalho e estão descritos em Pigatto Filho et al. (no prelo). São eles:

- **Complexidade Cirúrgica:** dada pelo *Guy's Score*, o qual é uma medida que identifica a gravidade de uma doença, no caso, a litíase urinária. Os subcritérios são dados por: “GUY1”, “GUY23”, “GUY4”, “GUY23_1”, “GUY23_23”, “GUY4_1”, “GUY4_23”, “GUY4_4”. O que significa que o paciente pode ter complicações em um dos rins ou nos dois, com graus de gravidade iguais ou diferentes, quando apresenta complicações nos dois rins. Por exemplo, o paciente que apresenta GUY1, possui o *guy's score* 1 em somente um rim.

Agora, o paciente que apresenta GUY4_23, apresenta o *guy's score* 4 num rim e 2 ou 3 no outro rim.

- **Disfunção orgânica:** separada em dois subcritérios: “**agravos da função renal**” e “**agravos de infecção e comorbidades**”.
 - O subcritério “**Agravos da função renal**” tem como subcritérios: Hidronefrose, obstrução calculosa, (“**Hidro**”); Doença Crônica Renal (“**DCR**”), Rim Único Funcional (“**1Rim**”) e litíase em Enxerto Renal (“**Rim_trans**”).
 - O subcritério “**agravos de infecção e comorbidades**” tem como subcritérios: Infecção urinária recorrente (“**IUR**”), “**Comorbidades**” e “**Nefrostomia**”.

- **Agravos Tempo-Sensíveis:** com subcritérios: Paciente portador de Cateter Duplo j (“**Duploj**”), Derivações Urinárias (“**Derivação**”) e Alto Metabolismo Calculoso (“**AltoMetabolismo**”).

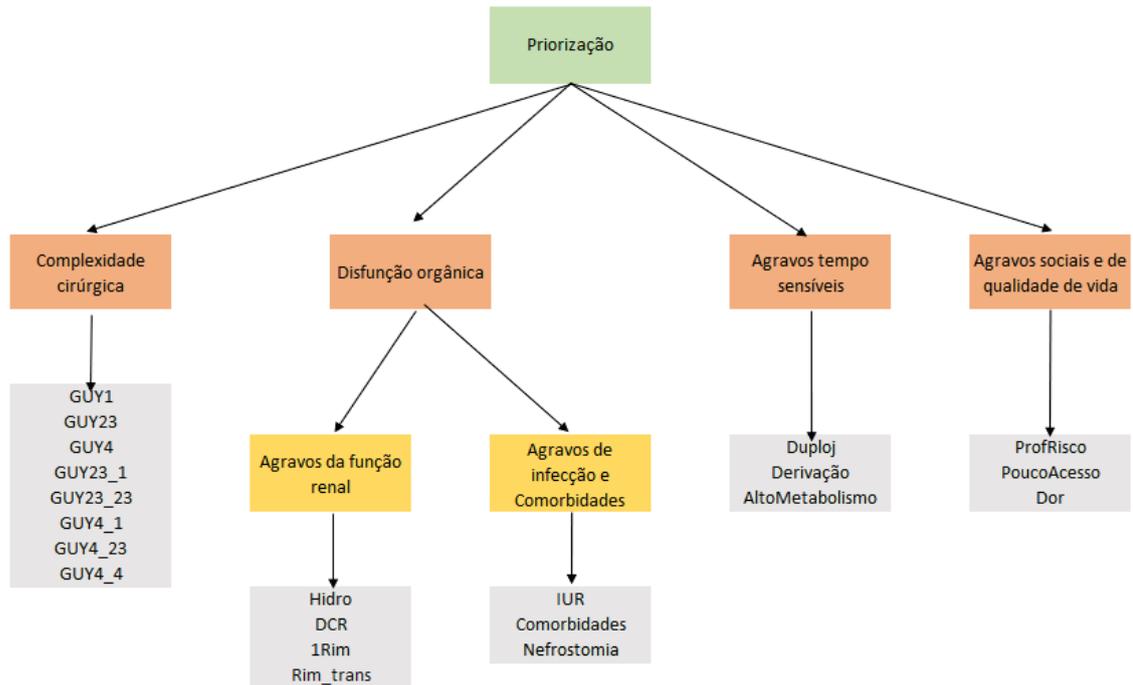
- **Agravos Sociais de Qualidade de Vida:** com subcritérios: Risco Ocupacional (“**ProfRisco**”), Difícil acesso ao Sistema de Saúde (“**PoucoAcesso**”) e Dor de difícil manejo ambulatorial (“**Dor**”).

Outras considerações sobre os critérios e subcritérios estão descritas em Pigatto Filho et al. (no prelo).

6.3.2 Estrutura hierárquica

A partir dos critérios mencionados acima, foi construída a árvore de decisão de acordo com a proposta de Saaty (1990), em que no primeiro nível estão os critérios e no segundo nível, os subcritérios. Além disso, para um dos subcritérios, há mais um nível de subcritério. A FIGURA 11 mostra esse esquema de hierarquia.

FIGURA 11 - HIERARQUIA DOS CRITÉRIOS



FONTE: A autora (2024).

6.3.3 Questionário AHP

Para preencher a matriz de comparação, dez especialistas em litíases urinárias responderam um questionário com perguntas que se referiam a comparação de cada critério par a par. As perguntas foram elaboradas em conjunto com pesquisadores urologistas do CHC, os quais participaram do desenvolvimento de parte dessa pesquisa. Desta forma, cada critério possui as perguntas de comparação par a par de cada um dos seus subcritérios. O campo “com relação as categorias” se refere a comparação entre os critérios do primeiro nível da hierarquia (“complexidade cirúrgica”, “disfunção orgânica”, “agravos tempo sensíveis” e “agravos sociais e de qualidade de vida”) e será chamado nesse trabalho de “critérios primários”. Já última linha, se refere a comparação entre os subcritérios “agravos da função renal” e “agravos de infecção e comorbidades”, do critério “disfunção orgânica”. Todas as perguntas do questionário estão descritas na FIGURA 12.

FIGURA 12 - PERGUNTAS DO QUESTIONÁRIO APLICADO AOS ESPECIALISTAS

COM RELAÇÃO A COMPLEXIDADE CIRURGICA

ENTRE UM PACIENTE COM SCORE GUY 1 E UM SCORE GUY 2 OU 3, QUAL TERIA PRIORIDADE?
 ENTRE UM PACIENTE COM SCORE GUY 1 E UM SCORE GUY 4, QUAL TERIA PRIORIDADE?
 ENTRE UM PACIENTE COM SCORE GUY 4 E UM SCORE GUY 2 OU 3, QUAL TERIA PRIORIDADE?
 ENTRE UM PACIENTE COM SCORE GUY 4 E UM QUE PRECISARA DE INTERVENÇÃO CIRURGICA CONTRALATERAL GUY 1, QUAL TERIA PRIORIDADE?
 ENTRE UM PACIENTE COM SCORE GUY 4 E UM QUE PRECISARA DE INTERVENÇÃO CIRURGICA CONTRALATERAL GUY 2/3, QUAL TERIA PRIORIDADE?
 ENTRE UM PACIENTE COM SCORE GUY 4 E UM QUE PRECISARA DE INTERVENÇÃO CIRURGICA CONTRALATERAL GUY 4, QUAL TERIA PRIORIDADE?
 ENTRE UM PACIENTE COM SCORE GUY 2 OU 3 E UM QUE PRECISARA DE INTERVENÇÃO CIRURGICA CONTRALATERAL GUY 1, QUAL TERIA PRIORIDADE?
 ENTRE UM PACIENTE COM SCORE GUY 2 OU 3 E UM QUE PRECISARA DE INTERVENÇÃO CIRURGICA CONTRALATERAL GUY 2/3, QUAL TERIA PRIORIDADE?

COM RELAÇÃO PACIENTE COM DISFUNÇÃO ORGANICA**AGRAVOS RELACIONADOS A FUNÇÃO RENAL**

ENTRE UM PACIENTE COM HIDRONEFROSE E CREATININA NORMAL, E UM PACIENTE COM DOENÇA RENAL CRONICA SEM HIDRONEFROSE, QUAL TERIA PRIORIDADE?
 ENTRE UM PACIENTE COM HIDRONEFROSE E CREATININA NORMAL, E UM PACIENTE COM APENAS UM RIM FUNCIONANTE (ESTE RIM NÃO ESTÁ OBSTRUÍDO E FUNÇÃO GLOBAL E NORMAL), QUAL TERIA PRIORIDADE?
 ENTRE UM PACIENTE COM HIDRONEFROSE, E UM PACIENTE COM LITÍASE EM UM RIM TRANSPLANTADO (O RIM TRANSPLANTADO NÃO ESTÁ OBSTRUÍDO), QUAL TERIA PRIORIDADE?
 ENTRE UM PACIENTE COM DOENÇA RENAL CRONICA (SEM OBSTRUÇÃO) E UM PACIENTE COM RIM ÚNICO FUNCIONAL (SEM OBSTRUÇÃO E COM FUNÇÃO GLOBAL NORMAL), QUAL TERIA PRIORIDADE?
 ENTRE UM PACIENTE COM DOENÇA RENAL CRONICA (SEM OBSTRUÇÃO) E UM PACIENTE COM LITÍASE EM UM RIM TRANSPLANTADO (ESTE ÚLTIMO SEM OBSTRUÇÃO E COM FUNÇÃO RENAL NORMAL), QUAL TERIA PRIORIDADE?
 ENTRE UM PACIENTE COM UM RIM ÚNICO FUNCIONANTE (SEM OBSTRUÇÃO E COM FUNÇÃO RENAL NORMAL) E UM PACIENTE COM UM RIM TRANSPLANTADO (SEM OBSTRUÇÃO E COM FUNÇÃO GLOBAL NORMAL), QUEM TERIA PRIORIDADE?

AGRAVOS RELACIONADOS A INFECÇÃO OU COMORBIDADES

ENTRE UM PACIENTE COM INFECÇÃO URINARIA RECORRENTE PROVAVELMENTE CORRELACIONADA AO CÁLCULO E UM PACIENTE COM UMA COMORBIDADE SISTEMICA IMPORTANTE (IMUNOSSUPRESSAO, ICC, DOENÇA VASCULAR, DEMENCIA, IMOBILIDADE), QUEM TERIA PRIORIDADE?
 ENTRE UM PACIENTE COM INFECÇÃO URINARIA RECORRENTE PROVAVELMENTE CORRELACIONADA AO CÁLCULO E UM PACIENTE COM NEFROSTOMIA, QUEM TEM PRIORIDADE?
 ENTRE UM PACIENTE COM COMORBIDADE SISTEMICA IMPORTANTE E UM PACIENTE COM NEFROSTOMIA, QUEM TEM PRIORIDADE?

AGRAVOS TEMPO SENSÍVEIS

ENTRE UM PACIENTE COM DUPLO J E UM PACIENTE QUE POSSUI UMA DERIVAÇÃO URINARIA, QUEM DEVE SER PRIORIZADO?
 ENTRE UM PACIENTE COM DUPLO J E UM PACIENTE COM ALTO METABOLISMO DO CÁLCULO (FORMA OU AUMENTA CALCULOS RAPIDAMENTE), QUEM DEVE SER PRIORIZADO?
 ENTRE UM PACIENTE COM UMA DERIVAÇÃO URINARIA E UM PACIENTE COM ALTO METABOLISMO DE CÁLCULO, QUEM DEVE SER PRIORIZADO?

AGRAVOS SOCIAIS E DE QUALIDADE DE VIDA

ENTRE UM PACIENTE COM UMA PROFISSAO DE RISCO (VIAJANTE OU PILOTO) E UMA PESSOA QUE MORA EM UM LUGAR COM POUCO ACESSO AO SISTEMA DE SAUDE (REGIOES REMOTAS OU DE DIFICIL ACESSO), QUEM TEM PRIORIDADE?
 ENTRE UM PACIENTE COM UMA PROFISSAO DE RISCO (VIAJANTE OU PILOTO) E UMA PESSOA QUE ESTE COM DOR DE DIFICIL MANEJO E PREJUZO NA QUALIDADE DE VIDA, QUEM TEM PRIORIDADE?
 ENTRE UM PACIENTE COM DIFICIL ACESSO AO SISTEMA DE SAUDE E UM PACIENTE COM DOR DE DIFICIL MANEJO CLÍNICO, QUEM TEM PRIORIDADE?

COM RELAÇÃO AS CATEGORIAS

ENTRE UM PACIENTE COM QUADRO CIRURGICO COMPLEXO E UM PACIENTE COM DISFUNÇÃO ORGANICA IMPORTANTE, QUEM TEM PRIORIDADE?
 ENTRE UM PACIENTE COM QUADRO CIRURGICO COMPLEXO E UM PACIENTE COM UM AGRAVO TEMPO SENSÍVEL, QUEM TEM PRIORIDADE?
 ENTRE UM PACIENTE COM QUADRO CIRURGICO COMPLEXO E UM PACIENTE COM UM AGRAVO SOCIAL OU DE QUALIDADE DE VIDA, QUEM TEM PRIORIDADE?
 ENTRE UM PACIENTE COM UMA DISFUNCAO ORGANICA E UM AGRAVO TEMPO SENSÍVEL, QUEM TEM PRIORIDADE?
 ENTRE UM PACIENTE COM UMA DISFUNCAO ORGANICA E UM COM AGRAVO SOCIAL OU DOR DE DIFICIL MANEJO, QUEM TEM PRIORIDADE?
 ENTRE UM PACIENTE COM AGRAVO TEMPO SENSÍVEL E UM PACIENTE COM AGRAVO SOCIAL OU DOR DE DIFICIL MANEJO, QUEM TEM PRIORIDADE?
 ENTRE UM PACIENTE COM AGRAVO A FUNCAO RENAL E UM PACIENTE COM ALTO RISCO DE SEPSE/ COMORBIDADES, QUEM TEM PRIORIDADE?

FONTE: A autora (2024).

6.3.4 Coleta de dados dos especialistas

Pela escala proposta por Saaty (1990), a comparação par a par recebe os valores de acordo com a sua importância. Para aplicar o método FAHP, esses números foram transformados em números triangulares Fuzzy, como em Lima Junior (2013). Desta forma, o QUADRO 4 apresenta esses novos valores para os números 1, 3, 5 e 7 da escala de Saaty, respectivamente.

QUADRO 4 - ESCALA DE JULGAMENTOS DE SAATY E NÚMEROS TRIANGULARES FUZZY

Escala de Saaty	Definição	Números Fuzzy
1	Mesma importância	(1,1,3)
3	Importância pequena de uma sobre a outra	(1,3,5)
5	Importância grande ou essencial	(3,5,7)
7	Importância muito grande ou demonstrada	(5,7,9)

FONTE: A autora (2022) adaptado de Saaty (1990).

Para exemplificar a resposta do questionário, o QUADRO 5 apresenta uma das matrizes obtidas pela resposta de um dos dez especialistas, respondentes do questionário, sobre o subcritério “agravos relacionados a infecção ou comorbidades”,

com os seus subcritérios “IUR”, “comorbidades” e “nefrostomia”. O QUADRO 6 apresenta a matriz de comparação par a par descrita anteriormente, agora com os números triangulares fuzzy.

QUADRO 5 - COMPARAÇÃO PAR A PAR DOS PESOS DOS CRITÉRIOS COM OS VALORES DA ESCALA DE SAATY PARA O CRITÉRIO “AGRAVOS RELACIONADOS A INFECÇÃO OU COMORBIDADES”.

Critérios	IUR	COMORBIDADES	NEFROSTOMIA
IUR	1	7	1/3
COMORBIDADES	1/7	1	1/5
NEFROSTOMIA	3	5	1

FONTE: A autora (2023).

QUADRO 6 - COMPARAÇÃO PAR A PAR DOS PESOS DOS CRITÉRIOS COM NÚMEROS TRIANGULARES FUZZY, PARA O CRITÉRIO “AGRAVOS RELACIONADOS A INFECÇÃO OU COMORBIDADES”.

Critérios	IUR	COMORBIDADES	NEFROSTOMIA
IUR	(1,1,1)	(5,7,9)	(1/5,1/3,1)
COMORBIDADES	(1/9,1/7,1/5)	(1,1,1)	(1/7,1/5,1/3)
NEFROSTOMIA	(1,3,5)	(3,5,7)	(1,1,1)

FONTE: A autora (2023).

Desta forma, para preencher a diagonal principal da matriz de comparação, em que cada critério é comparado com ele mesmo, foram usados o valor 1 (mesma importância entre os critérios). Na primeira linha e segunda coluna da comparação do QUADRO 5, por exemplo, “IUR” foi comparado com “comorbidades” e o especialista respondeu que “IUR” tem importância muito grande quando comparado com comorbidades, recebendo o valor 7. Como consequência, comparando “comorbidades” com “IUR”, descrito na segunda linha e primeira coluna no QUADRO 5, o valor recebido é o inverso de 7 (1/7). Com os números triangulares fuzzy, no QUADRO 6, o número 5 foi trocado por (3,5,7) e o seu inverso (1/7,1/5,1/3), como é proposto o inverso de um número triangular fuzzy em Zadeh (1965). Assim, seguindo esse raciocínio, foram preenchidas as demais comparações e matrizes de cada critério com seus subcritérios.

6.3.5 Cálculo dos pesos

O cálculo dos pesos foi realizado com o método FAHP e com o intuito de verificar o código construído, um exemplo foi resolvido com cálculos manuais e comparado com o resultado obtido pelo programa. O método foi implementado na

linguagem de programação Python e está descrito na seção 6.4.1, de acordo com a teoria do FAHP apresentada.

6.3.6 Coleta de dados dos pacientes

A coleta de dados dos pacientes foi realizada com 160 pacientes da fila de espera para a cirurgia NLPC no CHC. Os profissionais da saúde retiraram informações dos prontuários de pacientes incluídos nessa fila, sobre os critérios utilizados nesse trabalho. Após isso, essas informações foram transferidas para uma matriz no Excel, onde as linhas da matriz representam os pacientes e as colunas os critérios. Cada critério possui uma matriz dos pacientes e essas matrizes foram preenchidas com valores binários, ou seja, se o paciente apresenta o critério recebe o valor “1” e se não apresenta recebe o valor “0”. O QUADRO 7 apresenta um exemplo dessas matrizes dos pacientes para o critério “agravos da função renal”, com três pacientes.

QUADRO 7 - MATRIZ COM OS DADOS DOS PACIENTES REFERENTES AOS CRITÉRIOS

	Hidro	DCR	1_RIM	RIM_TRANS
Paciente 1	1	0	1	0
Paciente 2	0	0	1	0
Paciente 3	1	1	0	0

FONTE: A autora (2023).

A interpretação dos valores dessa matriz é a seguinte: O paciente 1 apresenta hidronefrose, possui somente um rim funcionando, não apresenta doença crônica renal e não possui rim transplantado. O paciente 2 possui somente um rim funcional, não apresenta hidronefrose, doença renal crônica e não possui rim transplantado. Já o paciente 3 possui hidronefrose, doença crônica renal, não possui somente um rim funcionando e não possui rim transplantado.

6.3.7 Cálculo do escore de gravidade (priorização dos pacientes)

A priorização dos pacientes foi realizada obtendo uma média ponderada dos pesos dos critérios com a matriz dos pacientes, para cada critério. Para exemplificar esse cálculo, será utilizada a matriz apresentada no QUADRO 8, e um exemplo para

o vetor (W) dos pesos do critério “agravos da função renal”, sendo “Hidro”, “DCR”, “1_RIM” e “RIM_TRANS” os subcritérios ocupando as posições 1, 2, 3 e 4 do vetor respectivamente. Assim, tem-se que:

A matriz dos pesos dos pacientes é dada por:

$$P = \begin{bmatrix} 1 & 0 & 1 & 0 \\ 0 & 0 & 1 & 0 \\ 1 & 1 & 0 & 0 \end{bmatrix}$$

O vetor dos pesos dos critérios, obtido pelo FAHP, é dado por:

$$W = (0,1; 0,4; 0,2; 0,3)^T$$

Multiplicando o vetor dos pesos W por cada linha da matriz P , temos a matriz das prioridades dos pacientes PP :

$$PP = \begin{bmatrix} 0,1 & 0 & 0,2 & 0 \\ 0 & 0 & 0,2 & 0 \\ 0,1 & 0,4 & 0 & 0 \end{bmatrix}$$

Agora, somando as colunas de cada linha da matriz PP , temos a prioridade do critério “agravos da função renal” de cada paciente, dada pelo vetor:

$$Prioridade = (0,3; 0,2; 0,5)^T$$

Sendo então a prioridade na fila para o Paciente 3, depois para o paciente 1 e depois para o paciente 2. Esse cálculo é realizado com todos os critérios e por fim, soma-se todos os vetores de prioridades dos critérios, obtendo a prioridade geral dos pacientes.

6.4 VERIFICAÇÃO E VALIDAÇÃO

6.4.1 Verificação (cálculo dos pesos)

O exemplo do cálculo dos pesos foi resolvido utilizando a resposta de um dos especialistas em relação ao subcritério “agravos relacionados a infecção ou comorbidades”, apresentado no QUADRO 6. Os passos do método e os resultados obtidos serão descritos abaixo:

1º passo: a matriz R , de comparação par a par dos pesos dos critérios, de um respondente fictício é:

$$R = \begin{bmatrix} (1,1,1) & (5,7,9) & (\frac{1}{5}, \frac{1}{3}, 1) \\ (\frac{1}{9}, \frac{1}{7}, \frac{1}{5}) & (1,1,1) & (\frac{1}{7}, \frac{1}{5}, \frac{1}{3}) \\ (1,3,5) & (3,5,7) & (1,1,1) \end{bmatrix}$$

2º passo: Para calcular os valores das extensões sintéticas de cada i , calcula-se a soma de todos os elementos da matriz e obtém-se o seu inverso, como mostra a expressão $[\sum_{i=1}^n \sum_{j=1}^m M_{g_i}^j]^{-1}$. Após, multiplicamos o número triangular fuzzy obtido, pelo somatório de todas as colunas da linha i , conforme (6). Desta forma, as extensões sintéticas obtidas, são:

$$S_1 = (0,2427, 0,4461, 0,8822)$$

$$S_2 = (0,0491, 0,0718, 0,1229)$$

$$S_3 = (0,1958, 0,4818, 0,0426)$$

3º passo: Os valores das comparações de números fuzzy, conforme (7), (8) e (9), foram:

$$V(S_1 \geq S_2) = 1$$

$$V(S_1 \geq S_3) = 0,9504$$

$$V(S_2 \geq S_1) = 0$$

$$V(S_2 \geq S_3) = 0$$

$$V(S_3 \geq S_1) = 1$$

$$V(S_3 \geq S_2) = 1$$

4º passo: Os pesos em relação a cada elemento, dados por (10) são:

$$d(C_1) = \min V(S_1 \geq S_2, S_1 \geq S_3) = (1; 0,9504) \Rightarrow d(C_1) = 0,9504$$

$$d(C_2) = \min V(S_2 \geq S_1, S_2 \geq S_3) = (0; 0) \Rightarrow d(C_2) = 0$$

$$d(C_3) = \min V(S_3 \geq S_1, S_3 \geq S_2) = (1,1) \Rightarrow d(C_3) = 1$$

5º passo: Então, o vetor dos pesos, como em (11), é:

$$W' = (0,94; 0; 1)^T$$

6º passo: E o vetor W' normalizado, de acordo com (12):

$$W = (0,4872; 0; 0,5127)^T$$

Sendo W um número não fuzzy.

Como mostra as prioridades dos critérios no QUADRO 8, a ordem dos critérios mais relevantes de acordo com o método FAHP utilizado é dada por C3 – C1 – C2, ou seja, “nefrostomia”, “IUR” e “comorbidades”.

QUADRO 8 - PRIORIDADE DOS CRITÉRIOS

Critério	Prioridade
C1	0,4872
C2	0
C3	0,5127

FONTE: A autora (2023).

O processo do cálculo dos pesos dos critérios foi realizado com a matriz obtida pela média das matrizes especialistas que responderam ao questionário, com seus números triangulares fuzzy. E a partir dessa matriz, aplicado o método proposto por Chang (1996).

6.4.2 Validação

Com o objetivo de verificar se os resultados do método estavam coerentes com a realidade, foi realizado um processo de validação da etapa anterior, considerando também o problema da NLPC. Desta forma, a validação do cálculo dos pesos foi realizada com quinze pacientes presentes na lista de espera e com um dos especialistas respondentes do questionário. Com isso, foi realizada uma priorização desses pacientes, fazendo uma média ponderada com os pesos dos critérios obtidos e as informações de cada paciente sobre cada critério. Essa priorização será detalhada no próximo tópico.

O processo de priorização possui três dados de entrada: as funções fuzzy, que são os números triangulares fuzzy; os pesos atribuídos pelos especialistas na comparação par a par dos critérios e os dados dos pacientes. A validação contou com 9 rodadas, as quais foram nomeadas de R1 até R9. A priorização obtida pelo método foi comparada com uma priorização obtida com os conhecimentos médicos do especialista, após foi calculada uma taxa de distância média, que compara a distância entre as respostas e obtém uma média dessas distâncias.

A validação foi iniciada solicitando ao especialista que colocasse em ordem de prioridade esses quinze pacientes, após isso essa ordem foi comparada com a ordem de prioridade obtida pelo método FAHP, a distância entre as respostas foi calculada e a média entre todas essas distâncias foi denominada de taxa de distância média, como mostra o QUADRO 9. Dessa forma, o QUADRO 9 apresenta a priorização dos pacientes obtida pelo FAHP na primeira coluna, a priorização feita pelo especialista na segunda coluna, a distância entre as respostas do método e do especialista na terceira coluna e a última linha está a taxa de distância média. Para esta validação, o cálculo do método foi realizado somente com as matrizes de comparação desse especialista.

QUADRO 9 – COMPARAÇÃO ENTRE AS PRIORIZAÇÕES DO FAHP E DO ESPECIALISTA NA PRIMEIRA RODADA

Priorização Fuzzy AHP	Priorização especialista	Distância entre as respostas
P13	P15	2
P3	P7	4
P7	P10	3

P13	P12	1
P11	P4	7
P5	P6	1
P2	P3	1
P10	P1	9
P3	P8	5
P12	P13	1
P6	P9	3
P1	P2	1
P9	P14	5
P13	P11	2
P7	P5	2
Taxa de distância média	-	3,133333333

FONTE: A autora (2024).

Essa primeira rodada foi chamada de R1 e nela foram utilizadas as funções fuzzy originais, os pesos originais do especialista e os dados originais dos pacientes. A taxa de distância média obtida foi aproximadamente 3,13. Nas rodadas seguintes, o cálculo dessa taxa seguiu o mesmo processo, com os ajustes necessários.

Na rodada R2, foram utilizadas as funções fuzzy originais, uma nova coleta para a comparação par a par dos critérios do primeiro nível e os dados originais dos pacientes. Essa nova coleta foi realizada, pois o especialista considerou o subcritério “duploj” com uma grande importância, mas o critério do primeiro nível “agravos tempo sensíveis”, ao qual o “duploj” está ligado, recebeu um peso baixo no seu julgamento, por isso foi necessário perguntar novamente a importância dos critérios do primeiro nível ao especialista. Essa nova coleta foi chamada de QCC2 e o resultado da taxa de distância média dessa rodada foi 3.

A rodada R3 foi realizada com as funções fuzzy originais, cada um dos pesos dos critérios do primeiro nível receberam um peso de 0,25 (QCC3) e os dados dos pacientes foram os originais. Nessa rodada, os pesos dos critérios do primeiro nível receberam os mesmos valores, pois foi discutido que ao responder o questionário com as comparações par a par desses critérios, os respondentes tiveram dificuldade de associá-los com os seus subcritérios, como no caso da rodada anterior, que o especialista considerou importante um subcritério, mas não deu muita importância ao critério que ele estava ligado. Ao fazer essa mudança, a taxa de distância média dessa rodada foi 2,86.

A rodada R4 foi realizada com as funções fuzzy originais, com os pesos dos critérios do primeiro nível iguais a 0,25, com uma nova coleta de dados para os critérios de terceiro nível pertencentes ao critério de segundo nível “agravos da função renal” e de primeiro nível “disfunção orgânica” (“HIDRO2”), e os dados originais dos pacientes. A decisão de fazer a nova coleta de dados para esse subcritério se deu pelo fato do especialista considerar o subcritério “hidro” de grande importância, mas no seu julgamento inicial ele recebeu um peso 0. Com essas duas mudanças nos pesos dos critérios a taxa de distância média dessa rodada foi de 2,73.

Após a realização das rodadas anteriores, foi possível notar que dois pacientes estavam com distâncias grandes comparando as priorizações, mas o Paciente 8 apresentou a maior distância, sendo colocado na primeira posição pelo especialista e nas priorizações do método ele ficava em posições inferiores a 10 na maioria das vezes. Após alguns questionamentos, o especialista mencionou que escolheu esse paciente devido a uma combinação de critérios, possuir hidronefrose e ter um rim funcionando, o que foi considerado diante do método proposto nesse trabalho e chegou a conclusão de que esse método não considera combinações de critérios, mas sim cada critério julgado separadamente. Dessa forma, observando esses dois critérios separadamente, o especialista colocou o paciente 8 na 11ª posição, mantendo os dados de entrada do R4, o que gerou uma taxa de distância média de 1,93. Essa foi a rodada R5.

Na rodada R6, foram usadas as funções fuzzy originais, com os novos pesos do critério do primeiro nível “QCC2” e do terceiro nível “HIDRO2”, com os dados dos pacientes originais, a ordem de priorização feita pelo especialista foi a terceira e a taxa de distância média obtida foi 1,93.

Nas rodadas R7 e R8, as funções fuzzy foram alteradas. Na rodada 7 foram usadas as funções fuzzy indicadas no QUADRO 10, os pesos dos critérios usados foram “QCC2” e “HIDRO2”, os dados dos pacientes foram os originais e a mudança na priorização foi a terceira. Com isso, a taxa de distância média obtida foi 2.

Na rodada 8, foram usadas as funções fuzzy indicadas no QUADRO 10, os pesos dos critérios usados foram “QCC2” e “HIDRO2”, os dados dos pacientes foram os originais e a mudança na priorização foi a terceira. A taxa de distância média obtida também foi 2.

Na rodada 9, as funções fuzzy foram as originais, o peso do critério QCC foi $QCC = (0,2;0,4;0,3;0,1)$ e o “HIDRO2”, os dados dos pacientes foram os originais e a mudança na priorização foi a terceira. A taxa de distância média obtida foi 2,26.

As informações dessas rodadas, com as alterações nos dados de entrada do método, as mudanças da priorização feita pelo especialista e os respectivos valores da taxa de distância média estão descritas no QUADRO 10.

QUADRO 10 - DESCRIÇÃO DAS RODADAS DA VALIDAÇÃO DO MÉTODO

Rodada	Funções fuzzy	Peso dos critérios	Dados dos pacientes	Mudança na priorização do especialista	Taxa de distância média
R1	Original	Original	Original	Primeira priorização	3,13
R2	Original	QCC2	Original	Primeira priorização	3
R3	Original	QCC3	Original	Primeira priorização	2,86
R4	Original	QCC3 e HIDRO2	Original	Segunda priorização: P4 na 11ª posição P14 na 12ª posição P15 na 5ª posição	2,73
R5	Original	QCC3, HIDRO 2	Original	Terceira priorização: P8 na 11ª posição e todos os outros antes da 11ª subiram uma posição	1,93
R6	Original	QCC2, HIDRO2	Original	Terceira priorização	1,93
R7	$(\frac{1}{2}, 1, 4)$ $(1, 3, 6)$ $(2, 5, 8)$ $(4, 7, 9)$	QCC2, HIDRO2	Original	Terceira priorização	2
R8	$(\frac{1}{2}, 1, 5)$ $(\frac{1}{3}, 3, 7)$ $(1, 5, 9)$ $(3, 7, 9)$	QCC2, HIDRO2	Original	Terceira priorização	2
R9	Original	$QCC=(0,2;0,4;0,3;0,1)$ HIDRO2	Original	Terceira priorização	2,26

FONTE: A autora (2023).

Nos QUADROS 11 e 12 estão as matrizes de comparação “QCC2” e “HIDRO2”, respectivamente, as quais foram alteradas durante o processo de validação. Desta forma, para preencher a diagonal principal da matriz de comparação,

em que cada critério é comparado com ele mesmo, foram usados o valor 1 (mesma importância entre os critérios). Na primeira linha e quarta coluna da comparação do QUADRO 11, por exemplo, “QCC” foi comparado com “AS_QV” e o especialista respondeu que QCC tem grande importância quando comparado com “AS_QV”, recebendo o valor 7. Como consequência, comparando “AS_QV” com “QCC”, descrito na quarta linha e primeira coluna no QUADRO 11, o valor recebido é o inverso de 7 (1/7). Assim, seguindo esse raciocínio, foram preenchidas as demais comparações e matrizes de cada critério com seus subcritérios.

QUADRO 11 - NOVOS PESOS PARA O CRITÉRIO “CRITÉRIOS PRIMÁRIOS”

QCC2	QCC	DOI	ATS	AS_QV
QCC	1	1/5	1/7	7
DOI	5	1	5	7
ATS	7	1/5	1	5
AS_QV	1/7	1/7	1/5	1

FONTE: A autora (2023).

QUADRO 12 - NOVOS PESOS PARA O CRITÉRIO “AGRAVOS RELACIONADOS A FUNÇÃO RENAL”

HIDRO2	Hidro	DCR	1RIM	RIM_TRA
Hidro	1	1	5	1/7
DCR	1	1	3	1/3
1RIM	1/5	1/3	0	1/5
RIM_TRA	7	3	5	1

FONTE: A autora (2023).

Ao fim da validação, foi possível verificar que as rodadas R5 e R6 obtiveram os menores valores para a taxa de distância média entre a resposta média do especialista e do método. Por isso, as matrizes de comparação “QCC” e “Hidro” serão substituídas pelas novas matrizes “QCC2” e “HIDRO2”, nos próximos passos do processo.

6.5 IMPLEMENTAÇÃO

A intenção para trabalhos futuros é implementar esse método numa plataforma de priorização, visando auxiliar as equipes de saúde nas tomadas de decisão de problemas reais. Mas, essa etapa não está no escopo deste trabalho.

7 ESTRUTURA DE REDE NEURAL PROPOSTA

A estrutura de rede neural proposta nesse trabalho, utiliza como resposta a priorização dos pacientes para a cirurgia de NLPC, que resultou do método Fuzzy AHP. Dessa forma, foram incluídos nessa abordagem os 160 pacientes do processo de priorização com o FAHP e os 21 subcritérios. Essa abordagem está separada em duas partes, na primeira parte foi proposta uma rede neural que classifica os pacientes em três categorias de prioridade (alta, média e baixa) e na segunda parte, os pacientes alocados em cada categoria são novamente priorizados na categoria em que estão, gerando uma ordenação desses pacientes na categoria. Para melhor compreensão, a rede neural utilizada na primeira parte será chamada de RN_1 e as utilizadas na segunda parte serão chamadas de RN_21 para a categoria de prioridade alta, RN_22 para a média e RN_23 para a baixa. Também serão descritos nessa seção, os testes computacionais realizados para analisar o desempenho dessa abordagem.

Toda a implementação foi realizada em linguagem computacional Python, utilizando a biblioteca Keras.

7.1 PRIMEIRA PARTE

A base de dados utilizada nessa primeira parte (RN_1) foi composta pelas informações dos critérios de cada paciente e sua pontuação de prioridade proposta pelo FAHP. Foram inseridas três colunas ao final da base de dados (y_1 , y_2 e y_3), e o conjunto dos 160 pacientes foi dividido em três partes, os 53 primeiros pacientes (alta prioridade) receberia $y_1=1$, $y_2=0$ e $y_3=0$. Os 53 pacientes seguintes (média prioridade), receberia $y_1=0$, $y_2=1$ e $y_3=0$. Por fim, os 54 pacientes finais (baixa prioridade) receberiam $y_1=0$, $y_2=0$ e $y_3=1$. Assim, foi construído o conjunto de dados para a aplicação de uma rede neural, com objetivo de classificar os pacientes em categorias. O QUADRO 13 apresenta um exemplo da montagem desse conjunto de dados. supondo que houvesse quatro critérios (C1, C2, C3, C4) e três pacientes (P1, P2 e P3).

QUADRO 13 - EXEMPLO DO CONJUNTO DE DADOS DA REDE NEURAL RN_1.

	Critério 1	Critério 2	Critério 3	Critério 4	y1	y2	y3
P1	1	1	0	1	1	0	0
P2	0	0	0	1	0	0	1
P3	0	0	1	1	0	1	0

FONTE: A autora (2024).

Dessa forma, as quatro colunas de critérios são as entradas da rede neural e as três colunas y são as respostas. Nesse exemplo, o Paciente 1 apresenta os critérios 1, 2 e 4 e ficou classificado como prioridade alta. O Paciente 2 como prioridade média e o Paciente 3, prioridade baixa.

A RN_1 foi construída com 21 neurônios na camada de entrada e foram propostas três arquiteturas para a realização de experimentos computacionais. As funções de ativação utilizadas nas camadas ocultas foram “Relu”, “Elu” e “Leaky Relu” e nas camadas de saída “*softmax*”. Foram realizados experimentos com 100, 300 e 500 épocas, o otimizador foi o “Adam”, a função de erro “*categorical crossentropy*” e a métrica utilizada “acurácia”. O conjunto de treino e teste foi dividido com 80% dos dados para treinamento e 20% para teste. Além disso, o conjunto de treino foi separado em 20% para a realização de uma validação do treino da rede neural, com o intuito de verificar o desempenho do modelo enquanto ele for treinado.

7.2 SEGUNDA PARTE

Nessa segunda parte, foi desenvolvida uma rede neural para cada categoria, RN_21, RN_22, RN_23 das categorias alta, média e baixa, respectivamente. A base de dados de cada rede neural foi composta também pelos critérios como sendo os dados de entrada, mas cada linha, ao invés de serem dados de um único paciente, foi composta por dois pacientes. Dessa forma, as linhas da base de dados continham todas as combinações de pacientes, dois a dois. A combinação dos pacientes foi realizada após a separação dos dados em conjunto de treinamento e de testes, sendo realizada a combinação dois a dois desses pacientes, no conjunto de treinamento e no conjunto de testes. A coluna de resposta apresentava um valor 1 quando o primeiro paciente era prioritário em relação ao segundo e 0 se o primeiro paciente não era prioritário em relação ao segundo, sendo verificada a prioridade com o resultado do método FAHP. O QUADRO 14 mostra um exemplo de como essa base de dados foi construída, supondo que houvesse quatro critérios (C1, C2, C3, C4) e três outros

pacientes (P1, P2 e P3), supondo agora que esses pacientes pertençam a categoria y_1 .

QUADRO 14 - EXEMPLO DOS CONJUNTOS DE DADOS DAS REDES NEURAIS RN_21, RN_22, RN_23

	C1	C2	C3	C4	C1	C2	C3	C4	Resposta
P1 e P2	1	1	0	1	0	0	1	1	1
P1 e P3	1	1	0	1	0	0	1	1	1
P2 e P3	0	0	0	1	0	0	1	1	0

FONTE: A autora (2024).

Dessa forma, o QUADRO 14 mostra, em cada linha, a combinação dois a dois desses pacientes, nas oito primeiras colunas estão os critérios, quatro do primeiro paciente e quatro do segundo e na última coluna está a resposta. Então, de acordo com a priorização obtida pelo FAHP, o paciente 1 tem prioridade sobre o paciente 2, desta forma, a coluna resposta recebeu o valor 1, na segunda linha, mostra que o paciente 1 também tem prioridade sobre o paciente 3, obtendo um valor 1 na coluna resposta, mas na terceira linha, o paciente 2 não tem prioridade sobre o paciente 3, então, a coluna resposta apresenta o valor 0.

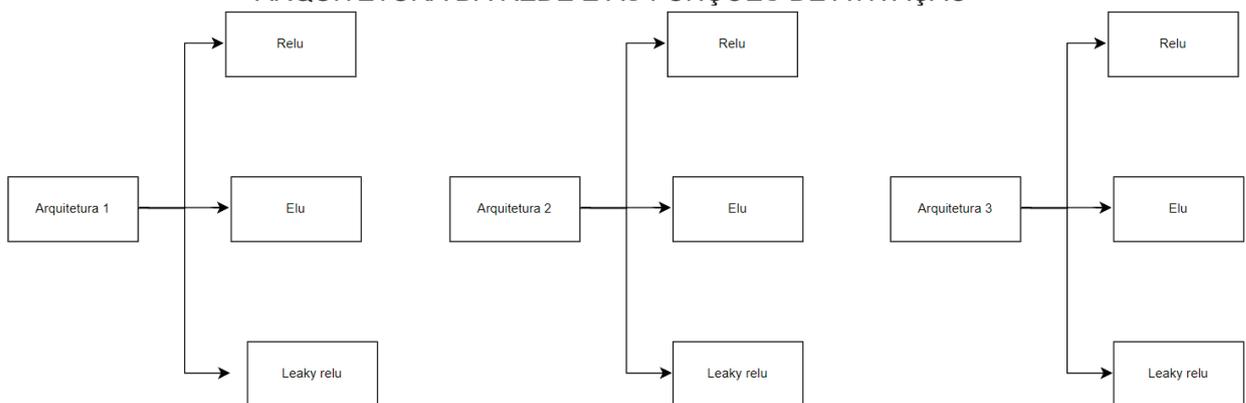
Do total de 160 pacientes, a quantidade de pacientes que foram alocados na RN_21 foi de 53, sendo 42 pacientes para o treinamento e 11 para o teste. O que gerou 861 linhas no conjunto de dados de treinamento, após a combinação dois a dois e 55 linhas no conjunto de teste. Essas mesmas quantidades foram obtidas na RN_22. A RN_23 possuía 54 pacientes, sendo 43 para o conjunto de teste e 11 para o conjunto de treinamento. Após a combinação, o conjunto de treinamento ficou com 903 linhas no conjunto de dados e o conjunto de teste ficou com 55 linhas.

As RN_21, RN_22 e RN_23 foram construídas com 46 neurônios na camada de entrada e foram propostas três arquiteturas para a realização de experimentos computacionais. As funções de ativação utilizadas nas camadas ocultas foram “Relu”, “Elu” e “Leaky Relu” e na camada de saída a função “sigmoid”. Foram realizados experimentos com 100, 300 e 500 épocas, o otimizador foi o “Adam”, a função de erro “binary crossentropy” e a métrica utilizada “acurácia”. O conjunto de treino e teste foi dividido com 80% dos dados para treino e 20% para teste. Além disso, o conjunto de treino também foi separado em 20% para a realização da validação do treino da rede neural.

7.3 EXPERIMENTOS COMPUTACIONAIS

Para analisar o desempenho da abordagem de rede neural proposta, serão realizados três conjuntos experimentos computacionais e verificados os erros e a acurácias de cada rede para o conjunto de teste. Para iniciar os experimentos, serão construídas três arquiteturas de redes neurais (Arqui_1, Arqui_2 e Arqui_3) tanto para RN_1 quanto para as RN_21, RN_22 e RN_23, variando o número de camadas ocultas e a quantidade de neurônios em cada camada. Dessa forma, no primeiro conjunto de experimento, para cada arquitetura serão variadas três Funções de Ativação (“*relu*”, “*elu*” e “*leaky relu*”), como mostra a FIGURA 13.

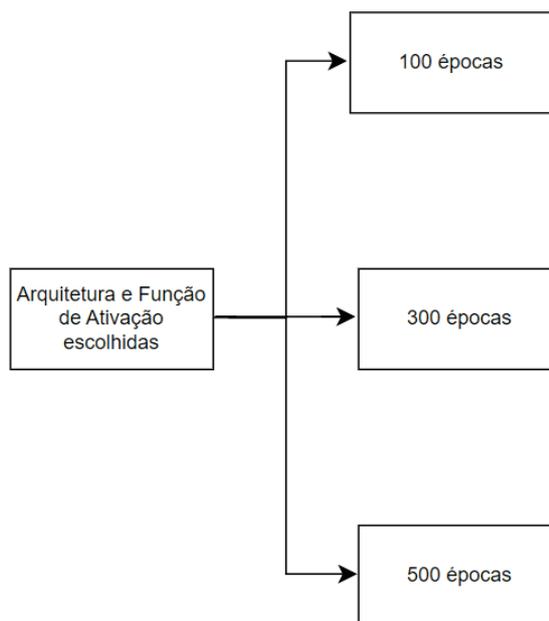
FIGURA 13 – ESQUEMA DOS EXPERIMENTOS COMPUTACIONAIS ALTERANDO A ARQUITETURA DA REDE E AS FUNÇÕES DE ATIVAÇÃO



FONTE: A autora (2024).

Após isso, será verificado qual dessas combinações entre arquitetura e função de ativação obteve o melhor desempenho. Então, a arquitetura e a função de ativação que forem escolhidas serão utilizadas no segundo conjunto. Dessa forma, no segundo conjunto de experimentos, o que será variado é o número de épocas (100 épocas, 300 épocas e 500 épocas), como mostra a FIGURA 14.

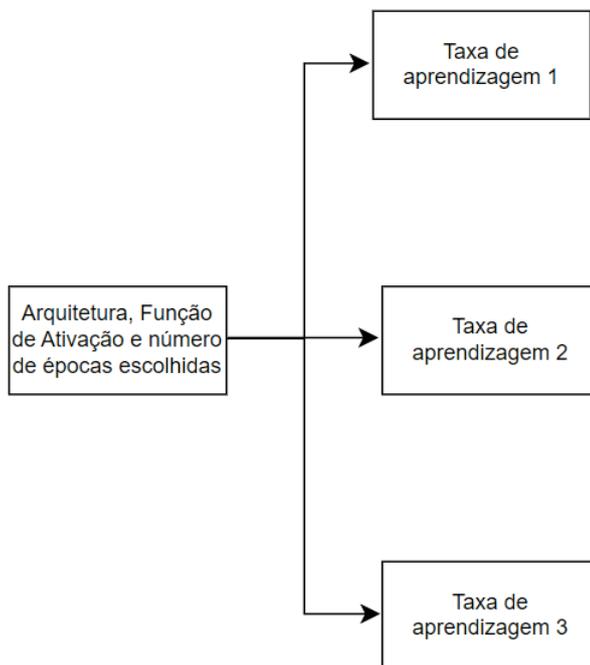
FIGURA 14 - ESQUEMA DOS EXPERIMENTOS COMPUTACIONAIS ALTERANDO O NÚMERO DE ÉPOCAS



FONTE: A autora (2024).

Por fim, no terceiro conjunto de experimentos, serão fixadas novamente a arquitetura e a função de ativação escolhidas, e agora o número de épocas que obteve o melhor desempenho. Com isso, serão variados três valores para a taxa de aprendizagem das redes neurais Tx_Apren_1, Tx_Apren_2 e Tx_Apren_3 (0,001, 0,01 e 0,1), como mostra a FIGURA 15.

FIGURA 15 - ESQUEMA DOS EXPERIMENTOS COMPUTACIONAIS ALTERANDO A TAXA DE APRENDIZAGEM



FONTE: A autora (2024).

Esse processo será repetido 50 vezes em cada rede neural proposta (RN_1, RN_21, RN_22 e RN_23) e com a análise dos resultados, será possível identificar qual cenário apresenta um melhor desempenho para essas redes neurais.

8 RESULTADOS

Esse capítulo apresenta os resultados dos pesos dos critérios para a cirurgia NLPC, obtidos com o método FAHP, os resultados da prioridade dos pacientes da fila de espera para a NLPC e dos experimentos computacionais realizados para analisar o desempenho da abordagem de redes neurais.

8.1 PRIORIZAÇÃO DOS CRITÉRIOS

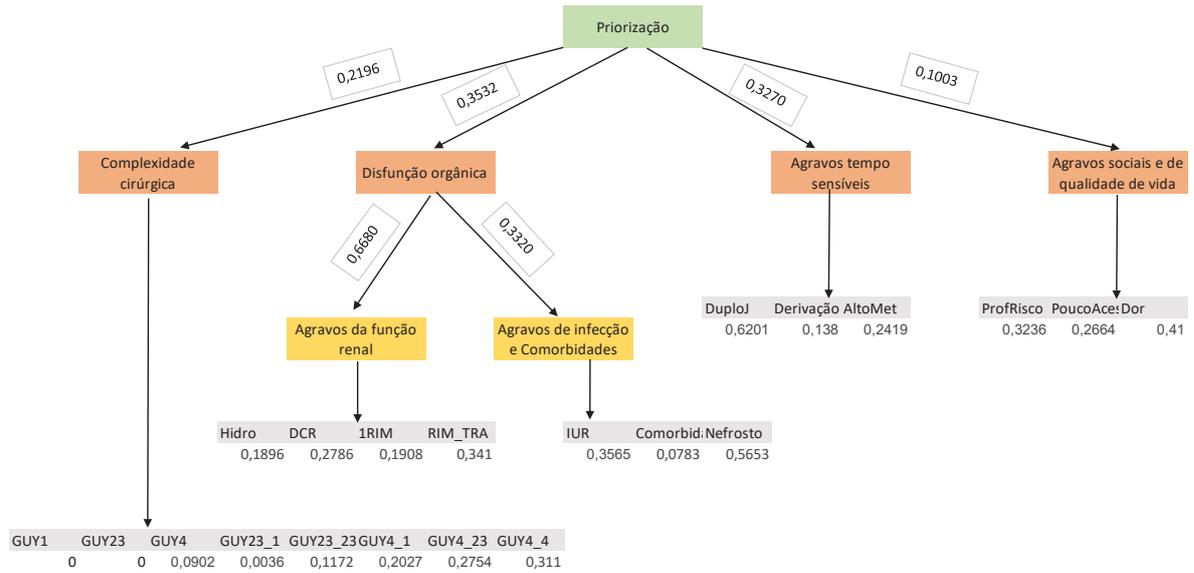
Os resultados obtidos no cálculo dos pesos dos critérios com o FAHP, são apresentados no QUADRO 15 e na árvore de decisão na FIGURA 16.

QUADRO 15 – RESULTADO DA PRIORIZAÇÃO DOS CRITÉRIOS

Resultado da priorização dos critérios					
Complexidade cirúrgica	GUY1	0,0000	Agravos relacionados a função renal	Hidro	0,1896
	GUY23	0,0000		DCR	0,2786
	GUY4	0,0902		1RIM	0,1908
	GUY23_1	0,0036		RIM_TRANS	0,3410
	GUY23_23	0,1172			
	GUY4_1	0,2027	Agravos relacionados a infecção ou comorbidades	IUR	0,3565
	GUY4_23	0,2754		Comorbidade	0,0783
	GUY4_4	0,3110		Nefrostomia	0,5653
Agravos tempos sensíveis	DuploJ	0,6201	Critérios primários	QCC	0,2196
	Derivação	0,1380		DOI	0,3532
	AltoMetabolismo	0,2419		ATS	0,3270
		AS_QV		0,1003	
Agravos sociais e de qualidade de vida	ProfRisco	0,3236			
	PoucoAcesso	0,2664	Agravos sistêmicos	AFR	0,6680
	Dor	0,4100		RS/C	0,3320

FONTE: A autora (2023).

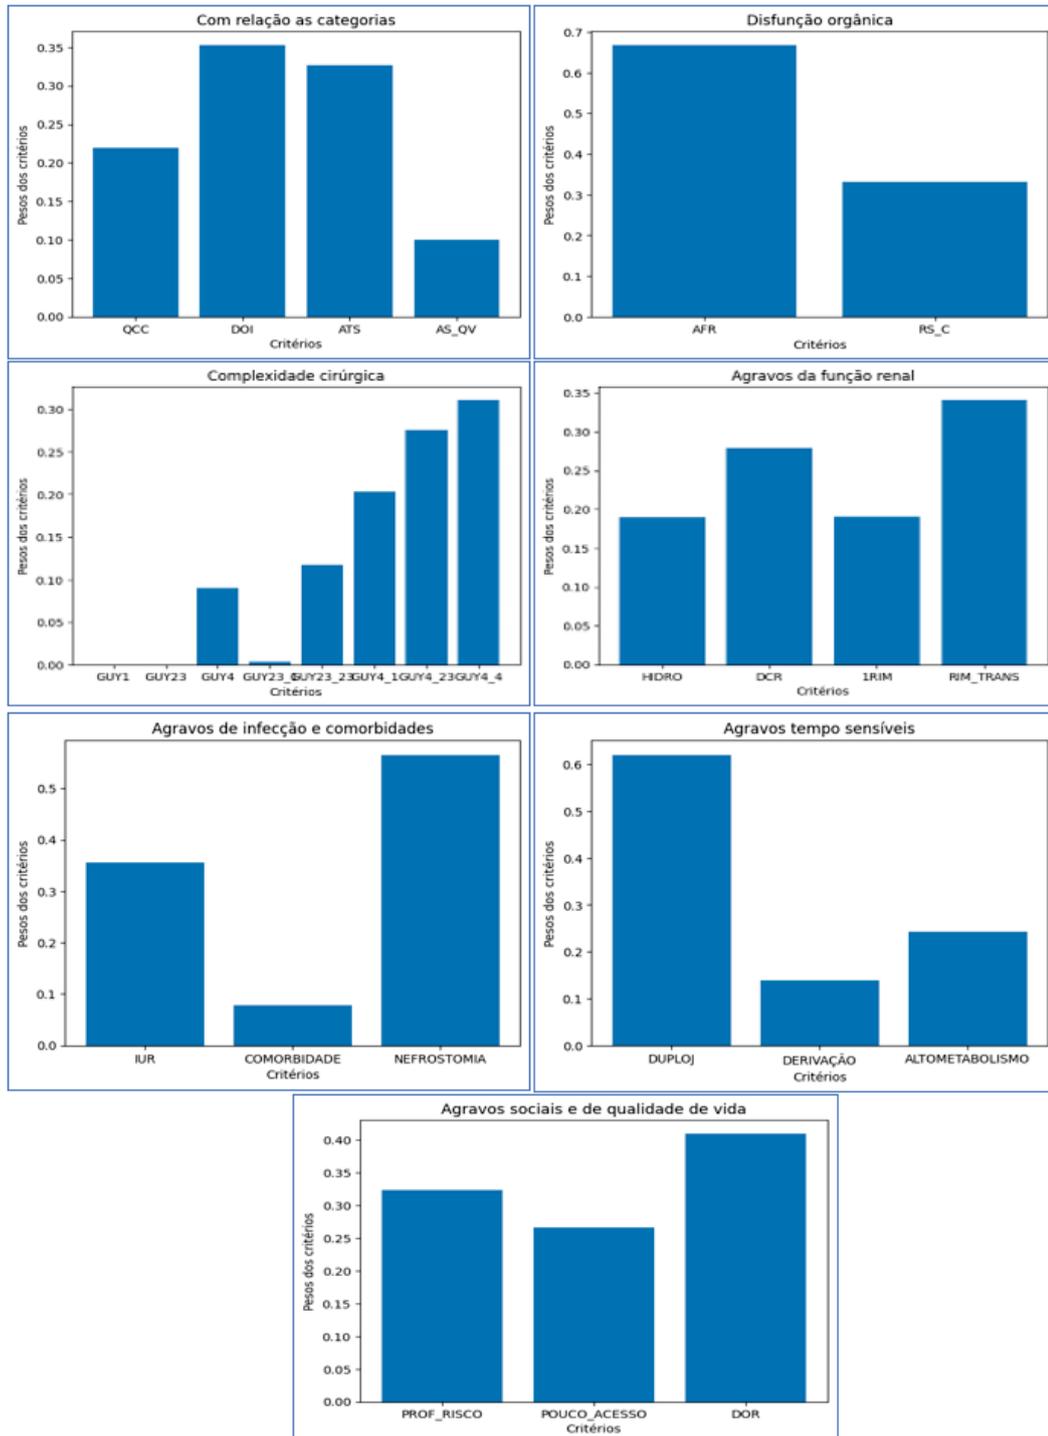
FIGURA 16 - HIERARQUIA COM O RESULTADO DA PRIORIZAÇÃO DOS CRITÉRIOS



FONTE: A autora (2023).

A FIGURA 17 apresenta os gráficos de barras com os pesos obtidos pelo FAHP para cada subcritério do problema da fila de espera para a NLPC.

FIGURA 17 - GRÁFICOS DE BARRAS COM O PESO DE CADA CRITÉRIO



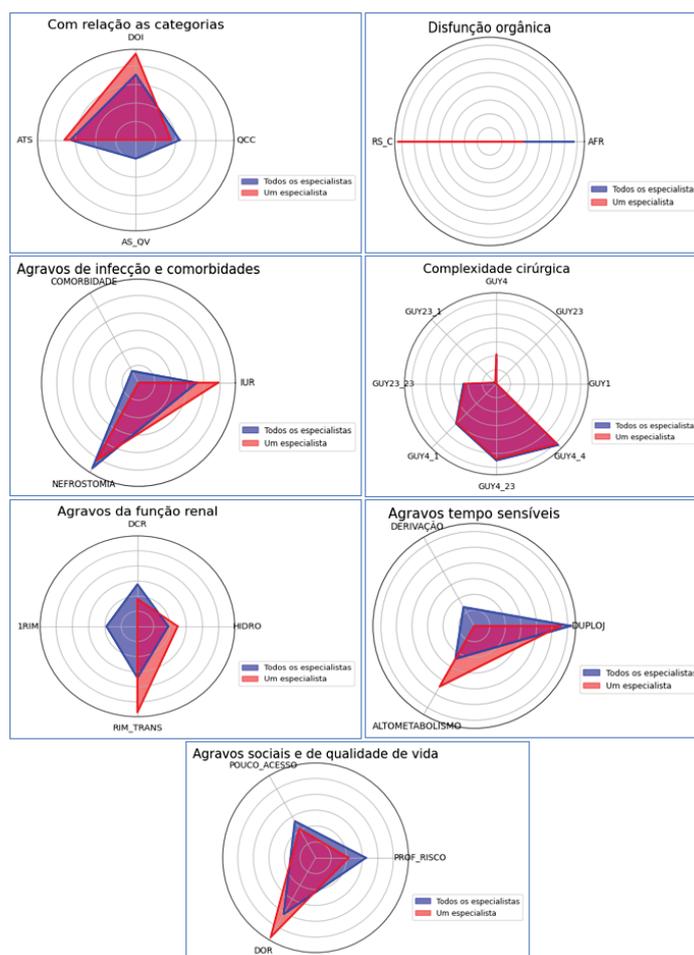
FONTE: A autora (2023).

Com a análise da tabela, da árvore de decisão e dos gráficos, os resultados mostraram que em relação a complexidade cirúrgica, o subcritério “GUY4_4” obteve maior prioridade em relação aos outros, seguido de “GUY4_23”, “GUY4_1”, “GUY23_23”, “GUY4”, “GUY23_1” e por último “GUY1” e “GUY23”, ambos com zero. Com relação a agravos relacionados a função renal a prioridade, em ordem decrescente foi “Rim_trans”, “DCR”, “1 Rim” e “Hidro”. No critério “agravos

relacionados a infecção ou comorbidades”, a maior prioridade foi para a “Nefrostomia”, depois “IUR” e por fim, “comorbidade”. Em “agravos de tempos sensíveis”, a ordem de priorização foi “Duploj”, “altometabolismo” e “derivação”. Em “agravos sociais e de qualidade de vida”, a maior prioridade foi para “dor”, seguido de “ProfRisco” e PoucoAcesso. No critério “critérios primários” (descrito como “com relação as categorias” na FIGURA 17), “DOI” apresentou maior prioridade, seguido de “ATS”, “QCC” e “AS_QV”. Por fim, no critério agravos sistêmicos, o critério “AFR” é prioritário em relação ao “RS/C”.

A FIGURA 18 apresenta um gráfico de radar comparando dois resultados de priorização dos critérios, um com base nas respostas do questionário de um único especialista e o outro no resultado obtido a partir das respostas do grupo completo de dez especialistas. Essa comparação permite visualizar as diferenças na priorização individual em relação à priorização do grupo todo. O critério “Com relação as categorias”, apresentado na FIGURA 18, se refere ao “critério primário”.

FIGURA 18 - GRÁFICOS DE RADAR COMPARANDO O RESULTADO DE UM ESPECIALISTA COM O RESULTADO DO GRUPO TODO



FONTE: A autora (2023).

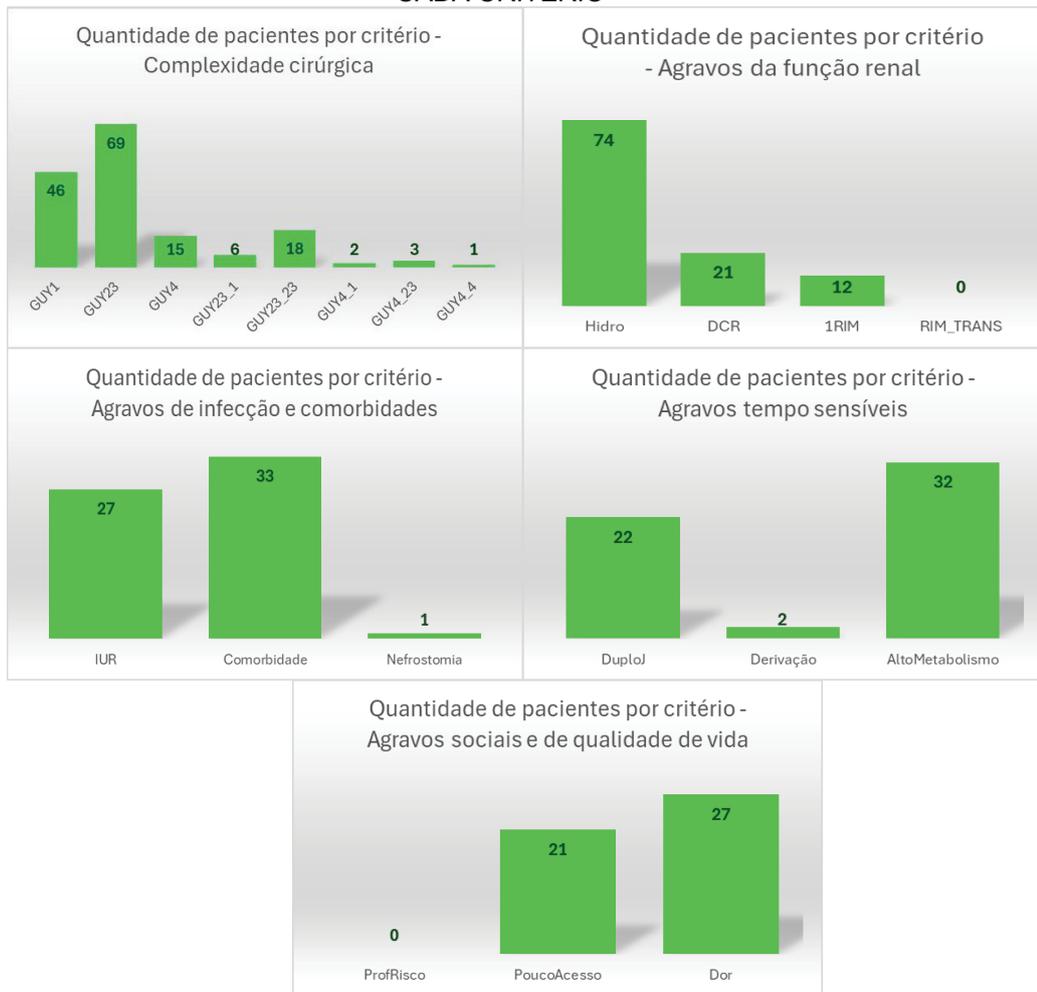
No geral, é possível notar pelos gráficos, que a resposta individual do especialista está em conformidade com as respostas do grupo, variando no peso da priorização. As respostas que apresentaram maiores diferenças foram dos subcritérios “Disfunção orgânica” e “Agravos relacionados a função renal”. Segundo a opinião individual do especialista sobre os subcritérios de “Disfunção orgânica”, o subcritério “RS_C” é mais importante do que “AFR”, enquanto o grupo pensa o contrário. Sobre o critério “Agravos da função renal”, o especialista opinou que “Hidro” é mais importante do que “DCR” e o grupo considerou “DCR” mais importante do que “Hidro”. Nos outros critérios as opiniões foram semelhantes, variando no valor do peso, mas com a mesma ordem de priorização.

8.2 PRIORIZAÇÃO DOS PACIENTES

A priorização dos pacientes ocorreu com dados de 160 pacientes na fila de espera para a cirurgia de NLPC, no CHC. Os dados coletados são referentes aos

critérios abordados nesse trabalho, conforme apresentado nas subseções 6.3.1 e 6.3.6. A FIGURA 19 apresenta a frequência dos pacientes em relação aos critérios, como por exemplo, no critério “Agravos de infecção e comorbidades” há 27 pacientes que apresentam “IUR”, 33 que apresentam “Comorbidade” e 1 que apresenta “Nefrostomia”.

FIGURA 19 - GRÁFICOS DE BARRAS COM A FREQUÊNCIA DOS PACIENTES EM RELAÇÃO A CADA CRITÉRIO



FONTE: A autora (2023).

O QUADRO 16 apresenta a fila em ordem de priorização obtida pelo FAHP, a ordem disponibilizada pelo hospital e a pontuação final do paciente. O QUADRO 16 apresenta também, uma classificação desses pacientes em três categorias. Na primeira categoria, em vermelho, estão os pacientes de alta prioridade, com 25% dos pacientes, média prioridade, em amarelo, com 50% e baixa prioridade, em azul, com 25%.

QUADRO 16 – RESULTADO DA PRIORIZAÇÃO COM FAHP

Fila após o fuzzy	Fila antiga	Escore	Fila após o fuzzy	Fila antiga	Escore
1	23	0,498905	81	66	0,070777
2	44	0,459833	82	72	0,070467
3	26	0,440095	83	84	0,067818
4	34	0,435222	84	6	0,065721
5	15	0,405212	85	64	0,064538
6	38	0,364181	86	11	0,053919
7	37	0,364181	87	79	0,053919
8	30	0,332156	88	39	0,053919
9	24	0,330392	89	105	0,053919
10	9	0,326844	90	48	0,050288
11	50	0,326583	91	2	0,050288
12	22	0,313462	92	56	0,046505
13	7	0,299914	93	141	0,045532
14	1	0,289282	94	106	0,045532
15	19	0,289282	95	32	0,045002
16	43	0,289282	96	146	0,044741
17	41	0,289282	97	118	0,044741
18	158	0,283366	98	139	0,044741
19	92	0,273206	99	136	0,044741
20	59	0,271033	100	132	0,044741
21	127	0,260409	101	124	0,044741
22	16	0,253719	102	149	0,044741
23	46	0,24748	103	160	0,044741
24	135	0,24386	104	103	0,044741
25	20	0,220838	105	62	0,044741
26	4	0,21854	106	101	0,044741
27	120	0,217388	107	10	0,044741
28	93	0,216534	108	70	0,044741
29	80	0,21445	109	18	0,044741
30	45	0,206444	110	88	0,044741
31	159	0,184311	111	49	0,044741
32	42	0,175456	112	63	0,044741
33	100	0,17334	113	83	0,044741
34	138	0,165647	114	55	0,044741
35	85	0,165426	115	13	0,041802
36	54	0,165215	116	75	0,04111
37	25	0,152525	117	95	0,04111
38	87	0,150332	118	33	0,04111
39	115	0,14957	119	67	0,035886
40	36	0,146921	120	97	0,035886
41	99	0,145939	121	53	0,035886
42	102	0,136188	122	51	0,026708
43	29	0,133283	123	68	0,026708
44	40	0,132356	124	81	0,026708

45	89	0,131537	125	110	0,026708
46	108	0,124635	126	129	0,025726
47	150	0,120213	127	73	0,019797
48	157	0,119639	128	21	0,019797
49	69	0,112559	129	147	0,019797
50	27	0,112559	130	114	0,009178
51	12	0,110723	131	119	0,009178
52	58	0,110462	132	112	0,009178
53	28	0,106602	133	122	0,009178
54	47	0,10634	134	57	0,009178
55	61	0,100625	135	78	0,009178
56	60	0,096353	136	94	0,000791
57	31	0,095029	137	156	0
58	131	0,091447	138	111	0
59	148	0,091246	139	152	0
60	5	0,089743	140	17	0
61	154	0,088307	141	35	0
62	143	0,086543	142	98	0
63	151	0,086543	143	107	0
64	155	0,085851	144	113	0
65	117	0,085851	145	125	0
66	14	0,085851	146	91	0
67	3	0,085851	147	96	0
68	144	0,082912	148	126	0
69	133	0,082912	149	65	0
70	153	0,080627	150	140	0
71	109	0,079894	151	121	0
72	8	0,079103	152	137	0
73	90	0,079103	153	71	0
74	145	0,079103	154	134	0
75	116	0,076996	155	74	0
76	77	0,074898	156	86	0
77	123	0,071449	157	76	0
78	82	0,071449	158	130	0
79	52	0,071449	159	128	0
80	142	0,071449	160	104	0

FONTE: A autora (2024).

8.3 ABORDAGEM DE REDES NEURAIIS

Para a rede neural de classificação apresentada na primeira parte da abordagem de redes neurais, (RN_1), e para as redes neurais de ordenação da segunda parte (RN_21, RN_22 e RN_23), foram realizados os experimentos computacionais em três etapas, para verificar o erro e a acurácia no conjunto de testes

das redes neurais. Desta forma, como está descrito no capítulo anterior, primeiro foram utilizadas as três arquiteturas propostas e para cada arquitetura uma função de ativação (“Relu”, “Elu” e “Leaky Relu”). Nessa etapa foram mantidos fixos o número de épocas em 300 e a taxa de aprendizagem em 0,001. Após serem escolhidas a melhor arquitetura e a melhor função de ativação, foram variados os números de épocas (100, 300 e 500 épocas). E por fim, ao ser escolhido também o número de épocas com o melhor desempenho, foram testados valores para a taxa de aprendizagem (0,1; 0,01 e 0,001). Cada uma dessas redes neurais foi calculada 50 vezes e verificado um resumo estatístico das informações dos erros e das acurácias das 50 redes neurais, além de dois gráficos de linhas, um para mostrar os erros e o outro para mostrar as acurácias. O resultado de todos os experimentos com o resumo estatístico e os gráficos de linhas estão no APÊNDICE deste trabalho e nas próximas subseções serão apresentados os resultados das configurações que apresentaram melhor desempenho em cada uma das redes de ordenação RN_1, RN_21, RN_22 e RN_23.

8.3.1 Primeira Parte (RN_1)

Para essa primeira parte foram escolhidas três arquiteturas. A primeira arquitetura possui uma camada de entrada com 21 neurônios, 4 camadas ocultas com 12, 8, 5 e 4 neurônios, respectivamente e uma camada de saída com 3 neurônios (21 -> 12 -> 8 -> 5 -> 4 -> 3). Na segunda arquitetura o número de camadas ocultas foi reduzido, ficando então com uma camada de entrada com 21 neurônios, 2 camadas ocultas com 15 e 9 neurônios, respectivamente e uma camada de saída com 3 neurônios (21 -> 15 -> 9 -> 3). Na terceira arquitetura foi acrescentada mais uma camada oculta, em relação a segunda arquitetura, ficando então com uma camada de entrada com 21 neurônios, 3 camadas ocultas com 17, 12 e 8 neurônios, respectivamente e uma camada de saída com 3 neurônios (21 -> 17 -> 12 -> 8 -> 3).

Dessa forma, o resultado do experimento que apresentou melhor desempenho para a RN_1 foi a primeira arquitetura com a função de ativação “Elu”. Ao variar o número de épocas, verificou-se que a utilização de 100 épocas não apresentou bom resultado e ao aumentar para 500 épocas também não melhorou o desempenho da rede. Desta forma, manteve-se o número de épocas em 300. Para a

taxa de aprendizagem também foi verificado que as taxas 0,1 e 0,01 não apresentaram bom resultado, mantendo então a taxa de aprendizagem em 0,001. Assim, a melhor configuração ficou com a primeira arquitetura, função de ativação “Elu”, 300 épocas e taxa de aprendizagem 0,001. A FIGURA 20 apresenta os resultados dessa configuração.

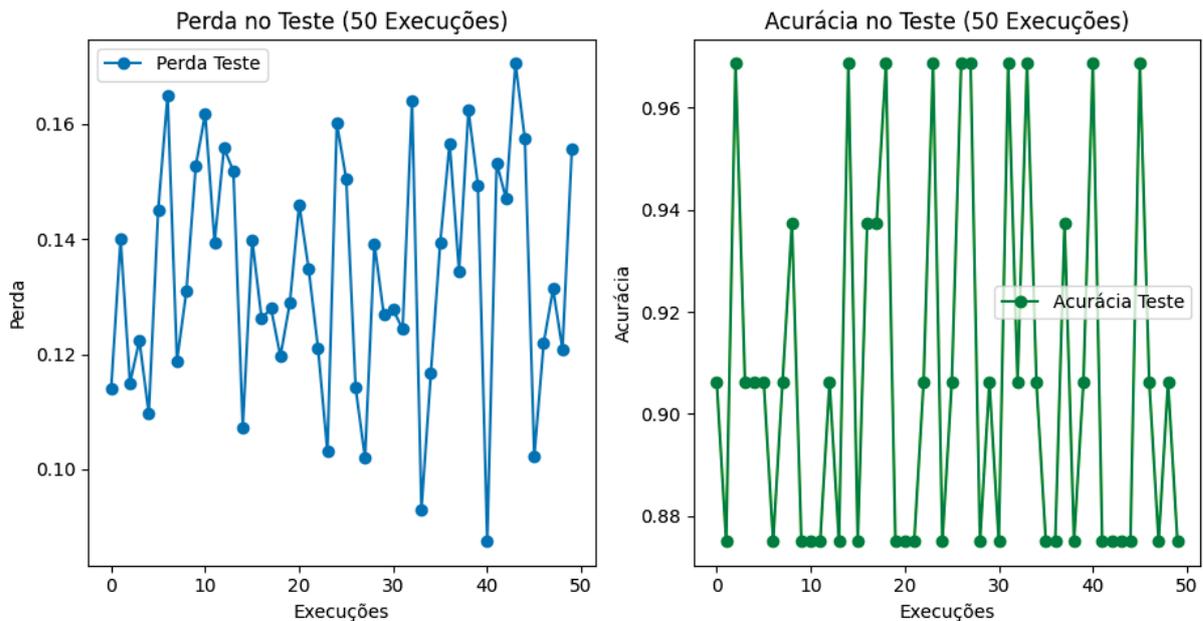
FIGURA 20 – RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_1, ARQUI_1. FUNÇÃO ELU, 300 ÉPOCAS E TAXA DE APRENDIZAGEM 0,001

Arqui_1 e Elu - Erro:

Estatística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 0.133746	Média dos erros
2	std 0.020499	Desvio padrão
3	min 0.087462	Valor mínimo
4	25% 0.119955	Primeiro quartil (25%)
5	50% 0.132904	Mediana (50%)
6	75% 0.151468	Terceiro quartil (75%)
7	max 0.170597	Valor máximo

Arqui_1 e Elu - Acurácia:

Estatística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.907500	Média das acurácias
2	std 0.036246	Desvio padrão
3	min 0.875000	Valor mínimo
4	25% 0.875000	Primeiro quartil (25%)
5	50% 0.906250	Mediana (50%)
6	75% 0.937500	Terceiro quartil (75%)
7	max 0.968750	Valor máximo



FONTE: A autora (2024).

De acordo com a FIGURA 20, essa configuração apresentou um valor mínimo de 0,09 de erro, um valor máximo de 0,17 e uma média de 0,13 (aproximadamente). Para a acurácia, o valor mínimo foi de 0,88, o valor máximo 0,97 e a média 0,91. O gráfico de linhas na FIGURA 20 mostra que os dados estão bem espalhados, tanto entre o erro quanto na acurácia, mas o intervalo em que os dados estão espalhados é pequeno. No gráfico do erro, é possível ver que há somente seis valores acima de 0,16, o restante se encontra abaixo desse valor. O gráfico da acurácia apresenta um espalhamento dos dados no intervalo de 0,87 e 0,97.

8.3.2 Segunda Parte (RN_21, RN_22 e RN_23)

Para a segunda parte também foram escolhidas três arquiteturas. A primeira arquitetura possui uma camada de entrada com 42 neurônios, 4 camadas ocultas com 21, 11, 6 e 3 neurônios, respectivamente e uma camada de saída com 1 neurônios (42 -> 21 -> 11 -> 6 -> 3 -> 1). Na segunda arquitetura o número de camadas ocultas foi reduzido, ficando com uma camada de entrada com 42 neurônios, 2 camadas ocultas com 28 e 14 neurônios, respectivamente e uma camada de saída com 1 neurônios (42 -> 28 -> 14 -> 1). Na terceira arquitetura foi também acrescentada mais uma camada oculta, em relação a segunda arquitetura, ficando então com uma camada de entrada com 42 neurônios, 3 camadas ocultas com 31, 20 e 9 neurônios, respectivamente e uma camada de saída com 1 neurônios (42 -> 31 -> 20 -> 9 -> 1).

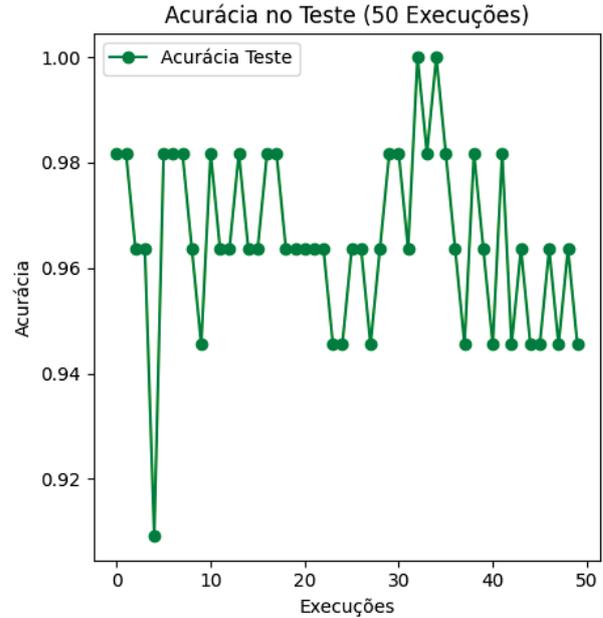
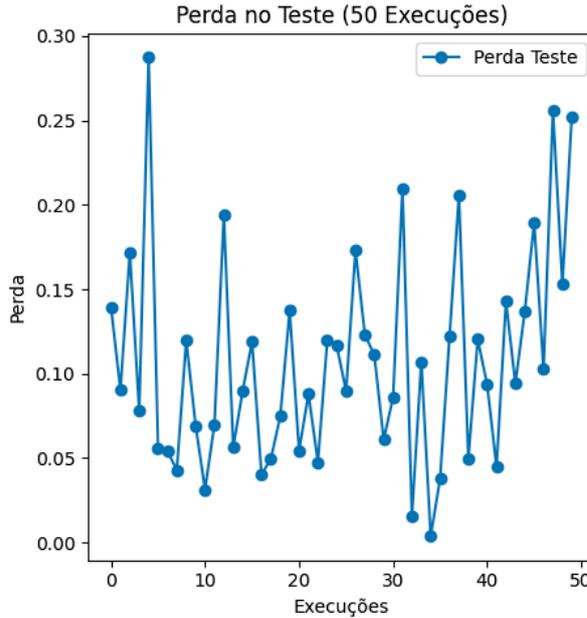
Dessa forma, o resultado do experimento que apresentou melhor desempenho para as RN_21 e RN_22 foi a segunda arquitetura com a função de ativação "Elu". Ao variar o número de épocas, verificou-se que a utilização de 100 épocas não apresentou bom resultado e ao aumentar para 500 épocas também não melhorou o desempenho da rede. Desta forma, manteve-se o número de épocas em 300. Para a taxa de aprendizagem também foi verificado que as taxas 0,1 e 0,01 não apresentaram bom resultado, mantendo então a taxa de aprendizagem em 0,001. Assim, a melhor configuração ficou com a segunda arquitetura, função de ativação "Elu", 300 épocas e taxa de aprendizagem 0,001. As FIGURAS 21 e 22 apresentam os resultados da configuração da RN_21 e RN_22, respectivamente.

FIGURA 21 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_21, ARQUI_2, FUNÇÃO ELU

Arqui_2 - Elu - Erro:

Arqui_2 - Elu - Acurácia:

Estatística	Erro	Descrição	Estatística	Acurácia	Descrição		
0	count	50.000000	Número de repetições	0	count	50.000000	Número de repetições
1	mean	0.107585	Média dos erros	1	mean	0.965455	Média das acurácias
2	std	0.063595	Desvio padrão	2	std	0.016933	Desvio padrão
3	min	0.003707	Valor mínimo	3	min	0.909091	Valor mínimo
4	25%	0.056190	Primeiro quartil (25%)	4	25%	0.963636	Primeiro quartil (25%)
5	50%	0.093844	Mediana (50%)	5	50%	0.963636	Mediana (50%)
6	75%	0.137297	Terceiro quartil (75%)	6	75%	0.981818	Terceiro quartil (75%)
7	max	0.287473	Valor máximo	7	max	1.000000	Valor máximo



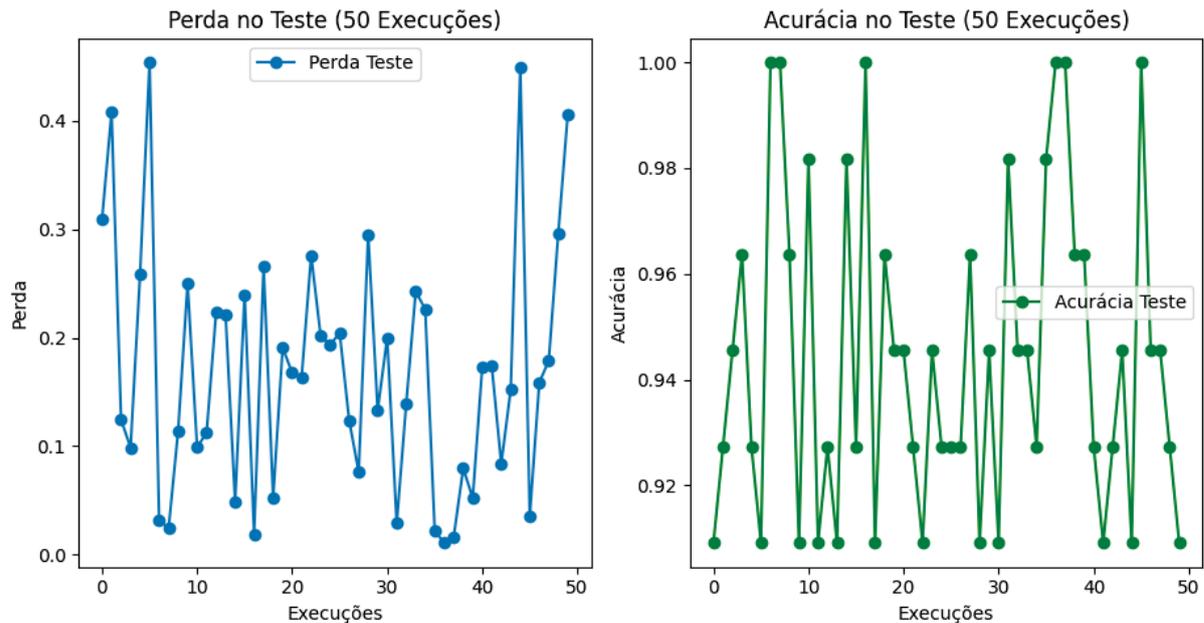
FONTE: A autora (2024).

De acordo com a FIGURA 21, a configuração da RN_21 apresentou um valor mínimo de 0,003 de erro, um valor máximo de 0,29 e uma média de 0,11 (aproximadamente). Para a acurácia, o valor mínimo foi de 0,90, o valor máximo 1,0 e a média 0,97. O gráfico de linhas da FIGURA 21 mostra que poucos valores de erro ficaram acima de 0, a maioria ficou abaixo desse valor. E do gráfico da acurácia é possível ver que a maioria dos dados estão acima de 0,94, somente um valor está abaixo de 0.94.

FIGURA 22 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_22, ARQUI_2, FUNÇÃO ELU

Arqui_2 - Elu - Acurácia:

Estadística	Erro	Descrição	Estadística	Acurácia	Descrição		
0	count	50.000000	Número de repetições	0	count	50.000000	Número de repetições
1	mean	0.170112	Média dos erros	1	mean	0.944000	Média das acurácias
2	std	0.114469	Desvio padrão	2	std	0.030255	Desvio padrão
3	min	0.010752	Valor mínimo	3	min	0.909091	Valor mínimo
4	25%	0.080642	Primeiro quartil (25%)	4	25%	0.927273	Primeiro quartil (25%)
5	50%	0.165673	Mediana (50%)	5	50%	0.945455	Mediana (50%)
6	75%	0.236525	Terceiro quartil (75%)	6	75%	0.963636	Terceiro quartil (75%)
7	max	0.453922	Valor máximo	7	max	1.000000	Valor máximo



FONTE: A autora (2024).

De acordo com a FIGURA 22, a configuração da RN_22 apresentou um valor mínimo de 0,01 de erro, um valor máximo de 0,45 e uma média de 0,17 (aproximadamente). Para a acurácia, o valor mínimo foi de 0,91, o valor máximo 1,0 e a média 0,94. O gráfico de linhas da FIGURA 22 mostra que poucos valores de erro ficaram acima de 0,3, a maioria ficou abaixo desse valor. E do gráfico da acurácia é possível ver que a maioria dos dados estão no intervalo entre os valores maiores que 0,91 e menores que 0,96.

Para a última rede, RN_23, o resultado do experimento apresentou que o melhor desempenho também ocorreu com a segunda arquitetura, mas com a função de ativação “Leaky Relu”. Ao variar o número de épocas, verificou-se que a utilização de 100 épocas não apresentou bom resultado e ao aumentar para 500 épocas também não melhorou o desempenho da rede. Desta forma, como observado nas outras redes, manteve-se o número de épocas em 300. Para a taxa de aprendizagem também foi verificado que as taxas 0,1 e 0,01 não apresentaram bom resultado,

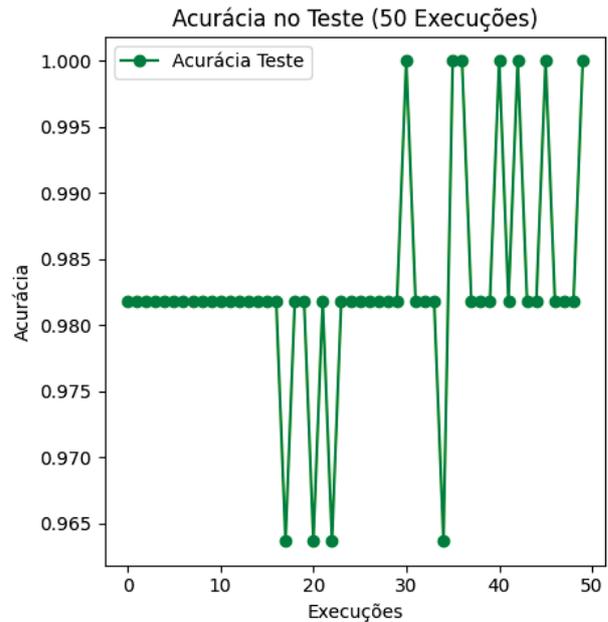
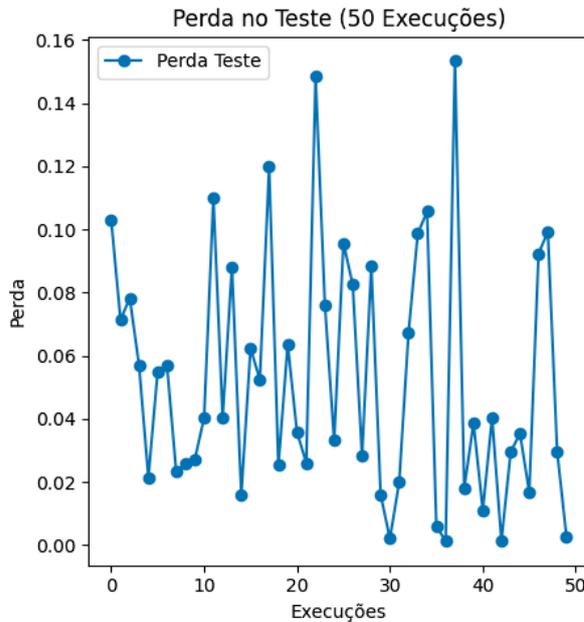
mantendo então a taxa de aprendizagem em 0,001, como ocorreu com as outras redes também. Assim, a melhor configuração ficou com a segunda arquitetura, função de ativação “Leaky Relu”, 300 épocas e taxa de aprendizagem 0,001. A FIGURA 23 apresenta os resultados da configuração da RN_23.

FIGURA 23 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_23, ARQUI_2, FUNÇÃO LEAKY RELU

Arqui_2 - Leaky ReLU - Erro:

Arqui_2 - Leaky ReLU - Acurácia:

Estatística	Erro	Descrição	Estatística	Acurácia	Descrição		
0	count	50.000000	Número de repetições	0	count	50.000000	Número de repetições
1	mean	0.052762	Média dos erros	1	mean	0.982909	Média das acurácias
2	std	0.038864	Desvio padrão	2	std	0.008544	Desvio padrão
3	min	0.001282	Valor mínimo	3	min	0.963636	Valor mínimo
4	25%	0.023749	Primeiro quartil (25%)	4	25%	0.981818	Primeiro quartil (25%)
5	50%	0.040376	Mediana (50%)	5	50%	0.981818	Mediana (50%)
6	75%	0.081397	Terceiro quartil (75%)	6	75%	0.981818	Terceiro quartil (75%)
7	max	0.153439	Valor máximo	7	max	1.000000	Valor máximo



FONTE: A autora (2024).

Dessa forma, a FIGURA 23 apresenta que a configuração da RN_23 obteve um valor mínimo de 0,001 de erro, um valor máximo de 0,15 e uma média de 0,05 (aproximadamente). Para a acurácia, o valor mínimo foi de 0,96, o valor máximo 1,0 e a média 0,98. O gráfico de linhas da FIGURA 23 mostra os dados do erro bem espalhados entre 0 e 0,1, com poucos valores acima de 0,1. E no gráfico da acurácia muitos valores se concentraram num valor de 0,98, aproximadamente. Poucos dados apresentaram resultados diferentes desse valor.

De uma forma geral, as quatro redes tiveram dificuldades de encontrar erros baixos, mas a acurácia se manteve alta em muitos dos experimentos. As redes

RN_21, RN_22 e RN_23 se comportaram melhor com uma arquitetura com poucas camadas, enquanto a RN_1 se comportou melhor com uma rede mais densa, com mais camadas. O aumento do número de épocas e a mudança na taxa de aprendizagem não foram úteis para encontrar melhores desempenhos para as redes. Mas em cada uma das redes pôde ser encontrada pelo menos uma configuração que apresentasse resultados satisfatórios de erros e acurácias.

Os demais resultados, tanto da primeira parte dos experimentos, quanto da segunda parte, estão no APÊNDICE deste trabalho.

9 CONSIDERAÇÕES FINAIS

Filas de espera são comuns nos ambientes hospitalares, quando não há recursos suficientes para atender todos os pacientes com necessidade de atendimento. Por isso, um processo de priorização de pacientes pode ser um auxílio para as equipes de saúde, buscando ajudar na tomada de decisões em ambientes hospitalares, sobre quais pacientes devem ter prioridade no atendimento. Os métodos multicritério de apoio a decisão são uma boa alternativa para lidar com esses problemas, dentre eles, está o AHP, no qual é possível organizar uma estrutura hierárquica de critérios e obter pesos para esses critérios de acordo com a opinião de especialistas. Desta forma, esse trabalho apresenta um processo de priorização de pacientes, utilizando um método AHP, combinado com a ideia de números triangulares fuzzy, para priorizar pacientes em filas de espera. Para exemplificar o processo, esse trabalho apresentou dois problemas, do COVID-19, sendo utilizado na etapa “definição dos critérios de priorização” e o problema da NLPC, utilizado nas etapas de “avaliação”, “validação e implementação”. Além disso, este trabalho apresenta uma abordagem de redes neurais que possa classificar e priorizar os pacientes, além de ser possível realizar previsões para novos pacientes.

Os resultados estão divididos em três partes, resultados da priorização dos critérios, da priorização dos pacientes e da abordagem de redes neurais. Sobre a priorização dos critérios, os subcritérios prioritários foram “DOI”, “AFR”, “GUY4_4”, “Rim_trans”, “Nefrostomia”, “Duploj” e “DOR”. Quando comparadas as respostas de um especialista individualmente com a resposta do grupo de todos os dez especialistas, os resultados mostraram uma conformidade, variando somente no peso da priorização em quase todos os subcritérios. Além disso, esses pesos foram satisfatórios e coerentes com a opinião da equipe de saúde que participou do desenvolvimento do artigo.

O resultado da priorização dos pacientes contou com uma nova fila de espera dos 160 pacientes da fila de espera para a cirurgia de NLPC do CHC em Curitiba-PR, priorizando aqueles pacientes com maior urgência de acordo com os critérios estabelecidos nesse trabalho e a opinião dos especialistas participantes. Além disso, essa fila foi separada em níveis de prioridade (alta, média e baixa), sendo possível escolher os primeiros pacientes de cada categoria com uma determinada porcentagem para cada nível, para que os pacientes do meio da fila e do final não

sejam totalmente prejudicados, agravando a doença.

Na abordagem de redes neurais, os experimentos computacionais no conjunto de teste mostraram que a melhor configuração para a RN_1 foi a primeira arquitetura, a função “elu”, 300 épocas e taxa de aprendizagem 0,001, obtendo um erro médio de 13% e uma acurácia média de 90%, aproximadamente. Para as redes RN_21 e RN_22 a configuração com melhor desempenho foi a segunda arquitetura, função “elu”, 300 épocas e taxa de aprendizagem 0,001. Os erros médios de RN_21 e RN_22 foram de 11% e 17%, respectivamente. As acurácias médias foram de 97% e 94%, respectivamente. Por fim, a última rede RN_23 obteve o melhor desempenho com a configuração utilizando a segunda arquitetura, a função de ativação “leaky relu”, 300 épocas e 0,001 de taxa de aprendizagem, com 5% de erro médio e 98% de acurácia média, aproximadamente.

Em trabalhos futuros será realizada a implementação desse processo em uma plataforma de priorização, que seja de fácil acesso para a equipe de saúde e que possa auxiliar na escolha de pacientes prioritários sobre problemas de qualquer tema. Além disso, é interessante realizar mais experimentos computacionais, variando parâmetros e mudando as arquiteturas das redes neurais, para melhorar o seu desempenho e para que essa abordagem seja uma ferramenta útil para a priorização de pacientes.

REFERÊNCIAS

ABDEL-HAFEZ, A. et al. Artificial intelligence in medical referrals triage based on Clinical Prioritization Criteria. **Frontiers in digital health**, v. 5, 26 out. 2023.

ALAKUS, T. B.; TURKOGLU, I. Comparison of deep learning approaches to predict COVID-19 infection. **Chaos, Solitons & Fractals**, v. 140, p. 110120, nov. 2020.

ALBAHRI, A. S.; AL-OBAIDI, J. R.; ZAIDAN, A. A.; et al. Multi-Biological Laboratory Examination Framework for the Prioritization of Patients with COVID-19 Based on Integrated AHP and Group VIKOR Methods. **International Journal of Information Technology and Decision Making**, v. 19, n. 5, p. 1247–1269, 2020. World Scientific.

ALUGUBELLI, R. Exploratory Study of Artificial Intelligence in Healthcare. **International Journal of Innovations in Engineering Research and Technology**, v. 3, n. 1, p. 1–10, 2016.

ASTOLFI, RH; CARRERA, R; GATTAS, N; BERTOLLA, R; SEPULVEDA, F; REGGIO, E; MELLER, AE. Current scenario of endourological treatment of kidney stones in brazil: results of a national survey. **Int Braz J Urol**, 2020 vol. 46(3) pp. 400-408.

AZER, S. M.; GOLDFARB, D. S. A summary of current guidelines and future directions for medical management and monitoring of patients with cystinuria. **Healthcare**, v. 11, n. 5, p. 674, 24 fev. 2023.

BAGULA, A.; LUBAMBA, C.; MANDAVA, M.; et al. Cloud based patient prioritization as service in public health care. **Proceedings of the 2016 ITU Kaleidoscope Academic Conference: ICTs for a Sustainable World, ITU WT 2016**, p. 1–8, 2017.

BOROFISKY, M. S. et al. Surgical decompression is associated with decreased mortality in patients with sepsis and ureteral calculi. **Journal of Urology**, v. 189, n. 3, p. 946-951, mar. 2013.

BRUYÈRE, F. et al. Infection et lithiase urinaire. **Progrès en Urologie**, v. 18, n. 12, p. 1015-1020, dez. 2008.

BURGHER, A.; BEMAN, M.; HOLTZMAN, J. L.; MONGA, M. Progression of Nephrolithiasis: Long-Term Outcomes with Observation of Asymptomatic Calculi. *Journal of Endourology* [Internet], v. 18, n. 6, p. 534–539, ago. 2004. Disponível em: <http://www.liebertpub.com/doi/10.1089/end.2004.18.534>. Acesso em: 24 jul. 2024.

CHANG, D.-Y. Applications of the extent analysis method on fuzzy AHP. **European Journal of Operational Research**, v. 95, n. 95, p. 649–655, 1996.

CITRAWATI, D. H. D.; WIDYAWATI, M. N.; SURYONO, S. The role of the analytic hierarchy process (AHP) algorithm in health care services. **Journal of Physics: Conference Series**, v. 1524, n. 1, 2020.

CRUZ, M. C.; REIS, L. Betabloqueadores no choque séptico: Já chegamos lá? **Revista Brasileira de Terapia Intensiva**, v. 29, n. 1, p. 1–3, 2017.

DAVENPORT, T.; KALAKOTA, R. The Potential for Artificial Intelligence in Healthcare. **SSRN Electronic Journal**, v. 6, n. 2, p. 94–98, 2019.

DEWITT-FOY, M. E. et al. Stones and moans: higher number of nephrolithiasis related encounters increases the odds of opioid misuse. **Urology**, v. 160, p. 75-80, fev. 2022.

EL-FAQIH, S. R. et al. Polyurethane internal ureteral stents in treatment of stone patients: morbidity related to indwelling times. **Journal of Urology**, v. 146, n. 6, p. 1487-1491, dez. 1991.

EREDICS, K. et al. Active stone removal is a safe option for octogenarians and nonagenarians with nephrolithiasis. **World Journal of Urology**, [s.l.], v. 41, n. 3, p. 849-856, 8 fev. 2023. Disponível em: <https://link.springer.com/10.1007/s00345-023-04304-3>. Acesso em: 20 ago. 2023.

FARSI, H. M. A. et al. Bacteriuria and colonization of double-pigtail ureteral stents: long-term experience with 237 patients. **Journal of Endourology**, v. 9, n. 6, p. 469-472, dez. 1995.

FIOCRUZ. Boletim Observatório Covid-19. Disponível em: <https://portal.fiocruz.br/sites/portal.fiocruz.br/files/documentos/boletim_extraordinario_2021-marco-16-red-red-red.pdf>. Acesso em: 10/8/2021.

FIOCRUZ. Nota técnica - Leitos de UTI para Covid-19 - Observatório Covid-19. Disponível em: <<https://portal.fiocruz.br/documento/nota-tecnica-leitos-de-uti-para-covid-19-15/2>>. Acesso em: 10/8/2021.

FRAZÃO, T. D. C.; CAMILO, D. G. G.; CABRAL, E. L. S.; SOUZA, R. P. Multicriteria decision analysis (MCDA) in health care: A systematic review of the main characteristics and methodological steps. **BMC Medical Informatics and Decision Making**, v. 18, n. 1, p. 1–17, 2018. BMC Medical Informatics and Decision Making.

FREE, R. C. et al. A data-driven framework for clinical decision support applied to pneumonia management. **Frontiers in Digital Health**, v. 5, 9 out. 2023.

GOLOMB, D. et al. Effect of age on presentation and outcome in renal colic. **Urologia Journal**, v. 90, n. 1, p. 36-41, 16 fev. 2023. Disponível em: https://journals.sagepub.com/doi/pdf/10.1177/03915603221116992?casa_token=-AAQ30ZBMcEAAAAA:8aoyU4hGsqSgx_ZQ7lpZQZPkqfbu3tl63SUI27VcOpIP4gD9eQsuZzUSiFsGXOdW7nv4nh1JmPzq64c. Acesso em: 20 ago. 2023.

GONCHAROV, M.; PISOV, M.; SHEVTSOV, A.; SHIROKIKH, B. Since January 2020 Elsevier has created a COVID-19 resource centre with free information in English and Mandarin on the novel coronavirus COVID- 19 . The COVID-19 resource centre is hosted on Elsevier Connect , the company ' s public news and information . , , n.

January, 2020.

GROOTHOFF, J. W. et al. Clinical practice recommendations for primary hyperoxaluria: an expert consensus statement from ERKNet and OxalEurope. **Nature Reviews Nephrology**, v. 19, n. 3, p. 194-211, 5 mar. 2023.

GUILLON-TANTAY, C. et al. Complications of non-continent cutaneous urinary diversion in adults with spinal cord injury: a retrospective study. **Spinal Cord**, v. 56, n. 9, p. 856-862, 7 set. 2018.

HAMASUNA, R. et al. Obstructive pyelonephritis as a result of urolithiasis in Japan: diagnosis, treatment and prognosis. **International Journal of Urology**, v. 22, n. 3, p. 294-300, mar. 2015. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/25400222/>. Acesso em: 20 ago. 2023.

HAMID, R. A.; ALBAHRI, A. S.; ALBAHRI, O. S.; ZAIDAN, A. A. Dempster–Shafer theory for classification and hybridised models of multi-criteria decision analysis for prioritisation: a telemedicine framework for patients with heart diseases. **Journal of Ambient Intelligence and Humanized Computing**, 2021. Springer Science and Business Media Deutschland GmbH.

HAYKIN, S. S. **Neural networks and learning machines**. New York: Prentice Hall/Pearson, 2009.

HEZAM, I. M.; NAYEEM, M. K.; FOUL, A.; ALRASHEEDI, A. F. COVID-19 Vaccine: A neutrosophic MCDM approach for determining the priority groups. **Results in Physics**, v. 20, 2021. Elsevier B.V.

JAMES, A. C.; LIN, D. W.; WRIGHT, J. L. Neobladders and continent catheterizable stomas for the bladder cancer survivor. **Current Opinion in Urology**, v. 24, n. 4, p. 407-414, jul. 2014. Disponível em: <https://journals.lww.com/00042307-201407000-00016>. Acesso em: 20 ago. 2024.

JEGATHEESWARAN, L.; TOLLEY, N. A Pilot Study of Augmented Intelligence Risk-Based Stratification for Endocrine Surgical Waiting List Prioritisation. **Cureus**, 6 out. 2022.

JIANG, F., JIANG, Y., ZHI, H., DONG, Y., LI, H., MA, S., WANG, Y., DONG, Q., SHEN, H., WANG, Y. Artificial intelligence in healthcare: past, present and future. **Stroke and Vascular Neurology**, v. 2, n. 4, p. 230-243, 2017.

KARALLIEDDE, J.; AYOTUNDE, A.; FRENCH, O.; NEWCOMBE, L.; BURNHILL, G.; SMITH, A.; MALHOTRA, B.; THOMAS, S.; SPELLMAN, C.; RAJASINGAM, D. A pragmatic digital health informatics based approach for aiding clinical prioritisation and reducing backlog of care: A study in cohort of 4022 people with diabetes. **Diabetes Research and Clinical Practice**, v. 203, p. 110834–110834, 1 set. 2023.

KEHINDE, E. O. et al. Factors predisposing to urinary tract infection after J ureteral stent insertion. **Journal of Urology**, v. 167, n. 3, p. 1334-1337, mar. 2002.

KIM, G. W. et al. Adaptive Stacking Ensemble Techniques for Early Severity Classification of COVID-19 Patients. **Applied Sciences**, v. 14, n. 7, p. 2715–2715, 24 mar. 2024.

KUKREJA, R; DESAI, M; PATEL, SH; DESAI, MR. Nephrolithiasis associated with renal insufficiency: factors predicting outcome. **J Endourol**, 2003 vol. 17(10) pp. 875-9.

LAARHOVEN, P. J. M. VAN; PEDRYCZ, W. A Fuzzy Extension of Saaty's Priority Theory. **Fuzzy Sets and Systems**, v. 11, p. 229–241, 1983.

LIMA JUNIOR, F. R. Comparação entre os métodos Fuzzy TOPSIS e Fuzzy AHP no apoio à tomada de decisão para seleção de fornecedores. **Teses.Usp.Br**, p. 150, 2013.

LI, Z. et al. Health-related quality of life (HRQoL), anxiety and depression in patients with ureteral stricture: a multi-institutional study. **World Journal of Urology**, v. 41, n. 1, p. 275-281, 5 dez. 2022.

MANDAVA, M.; LUBAMBA, C.; ISMAIL, A.; BAGULA, A.; BAGULA, H. Cyber-healthcare for public healthcare in the developing world. **Proceedings - IEEE Symposium on Computers and Communications**, v. 2016-Augus, p. 14–19, 2016. IEEE.

MARDIS, H. K. et al. Comparative evaluation of materials used for internal ureteral stents. **Journal of Endourology**, v. 7, n. 2, p. 105-115, abr. 1993.

MARGOLIN, E. J. et al. Predicting sepsis in patients with ureteral stones in the emergency department. **Journal of Endourology**, v. 36, n. 7, p. 961-968, 1 jul. 2022. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/35156856/>. Acesso em: 20 ago. 2024.

MCCARTHY, J. P.; SKINNER, T. A. A.; NORMAN, R. W. Urolithiasis in the elderly. **Canadian Journal of Urology**, v. 18, n. 3, p. 5717-5720, jun. 2011. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/21703047/>. Acesso em: 20 ago. 2024.

MCRAE, M. P.; SIMMONS, G. W.; CHRISTODOULIDES, N. J.; et al. Clinical decision support tool and rapid point-of-care platform for determining disease severity in patients with COVID-19. **Lab on a Chip**, v. 20, n. 12, p. 2075–2085, 2020. Royal Society of Chemistry.

MENG, L.; DONG, D.; LI, L.; et al. A Deep Learning Prognosis Model Help Alert for COVID-19 Patients at High-Risk of Death: A Multi-Center Study. **IEEE Journal of Biomedical and Health Informatics**, v. 24, n. 12, p. 3576–3584, 2020.

MOCHHALA, S. H.; WORCESTER, E. M. Primary hyperoxaluria: the adult nephrologist's point of view. **Clinical Kidney Journal**, v. 15, suplemento 1, p. i29-i32, 17 maio 2022.

MORENO-SANCHEZ, P. A. Development of an Explainable Prediction Model of Heart Failure Survival by Using Ensemble Trees. **Proceedings - 2020 IEEE**

International Conference on Big Data, Big Data 2020, p. 4902–4910, 2020.

MOULIK, S.; MISRA, S.; OBAIDAT, M. S. Smart-Evac: Big Data-Based Decision Making for Emergency Evacuation. **IEEE Cloud Computing**, v. 2, n. 3, p. 58–65, 2015. Institute of Electrical and Electronics Engineers Inc.

MÜHLBACHER, A. C.; KACZYNSKI, A. The Expert Perspective in Treatment of Functional Gastrointestinal Conditions: A Multi-Criteria Decision Analysis Using AHP and BWS. **Journal of Multi-Criteria Decision Analysis**, v. 23, n. 3–4, p. 112–125, 2016. John Wiley and Sons Ltd.

NEVES, H. R. A. das; ROCHA, R. de A.; DIAS, J. da S. Implementation of an expert system to determine eligibility and priorities for bone marrow transplants. **Studies in Health Technology and Informatics**, v. 84, p. 310-314, 2001.

NIELSEN, Michael A. Neural Networks and Deep Learning. Determination Press, 2015. Disponível em: <http://neuralnetworksanddeeplearning.com/>. Acesso em: 24 jul. 2024.

OLIVEIRA, M. et al. Assessing the impact of patient prioritization on operating room schedules. **Operations Research for Health Care**, v. 24, p. 100232, 1 mar. 2020.

OMOGBADEGUN, Z.; OGUNDELE, I.; OLADIPUPO, O. Applying Neural Network-based approach to Sickle Cell Disease-related pain classification. **Journal of Computer Science**, v. 15, n. 6, p. 861–872, 2019.

ÖZKAN, B.; ÖZCEYLAN, E.; KABAK, M.; DIKMEN, A. U. Evaluation of criteria and COVID-19 patients for intensive care unit admission in the era of pandemic: A multi-criteria decision making approach. **Computer Methods and Programs in Biomedicine**, v. 209, n. January, p. 1–12, 2021.

PÁDUA, A. I.; ALVARES, F.; MARTINEZ, J. A. B. Insuficiência Respiratória. **Medicina (Ribeirao Preto. Online)**, v. 36, n. 2/4, p. 205, 2003.

PEARLE, M. S. et al. Medical management of kidney stones: AUA guideline. **Journal of Urology**, v. 192, n. 2, p. 316-324, ago. 2014.

PECCHIA, L.; BATH, P. A.; PENDLETON, N.; BRACALE, M. Analytic Hierarchy Process (AHP) for examining healthcare professionals' assessments of risk factors: The relative importance of risk factors for falls in community-dwelling older people. **Methods of Information in Medicine**, v. 50, n. 5, p. 435–444, 2011.

PÉCORÁ, A. T. L.; DE FRAGA, R.; RUIZ, A.; FREGA, J. R.; PÉCORÁ, J. E. Developing a prioritization approach to managing patients' access to the Urodynamics exam. **Journal of Modern Project Management**, v. 8, n. 3, p. 53–61, 2021.

PIGATTO FILHO, G.; MACEDO, A. de F. M.; NICHELE, S. A.; FRAGA, R. de; PECORA JUNIOR, J. E.; VARGAS, F.; SANTOS, L. S. Development of a severity score for prioritizing patients in the percutaneous nephrolithotripsy queue: Fuzzy-

AHP method. *Journal of Business and Economics (JBE)*, No prelo.

QUIROZ, J. C.; FENG, Y.-Z.; CHENG, Z.-Y.; et al. 20. Development and Validation of a Machine Learning Approach for Automated Severity Assessment of COVID-19 Based on Clinical and Imaging Data - Retrospective Study.pdf.

RAHIMI, S. A. et al. Risk-based decision making framework for prioritizing patients' access to healthcare services by considering uncertainties. 1 out. 2015.

RAHIMI, S. A.; JAMSHIDI, A.; RUIZ, A.; AIT-KADI, D. A new dynamic integrated framework for surgical patients' prioritization considering risks and uncertainties. **Decision Support Systems**, v. 88, p. 112–120, 2016. Elsevier B.V. Disponível em: <<http://dx.doi.org/10.1016/j.dss.2016.06.003>>.

RAHIMI, S. A. et al. Prioritization of patients access to outpatient augmentative and alternative communication services in Quebec: a decision tool. **Disability and Rehabilitation: Assistive Technology**, p. 1–8, 5 jun. 2020.

RESORLU, B. et al. Can we avoid percutaneous nephrolithotomy in high-risk elderly patients using the Charlson Comorbidity Index? **Urology**, v. 79, n. 5, p. 1042-1047, maio 2012. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/22196410/>. Acesso em: 20 ago. 2023.

RINGEL, A. et al. Late complications of ureteral stents. **European Urology**, v. 38, n. 1, p. 41-44, 2000.

ROBERT, M. et al. Double-J ureteric stent encrustations: clinical study on crystal formation on polyurethane stents. **Urological International**, v. 58, n. 2, p. 100-104, 1997.

SAATY, T. L. How to make a decision: The analytic hierarchy process. **European Journal of Operational Research**, v. 48, n. 1, p. 9–26, 1990.

SAATY, T. L. Decision making with the analytic hierarchy process. **Int. J. Services Sciences**, v. 1, p. 83–98, 2008.

SAHNI, NIKHIL; STEIN, GEORGE; ZEMMEL, RODNEY; CUTLER, DAVID M. The potential impact of artificial intelligence on healthcare spending. Cambridge, MA: National Bureau of Economic Research, 2023. (Working Paper, n. 30857). Disponível em: <http://www.nber.org/papers/w30857>. Acesso em: 18 ago. 2024.

SHASHIKUMAR, S. P.; WARDI, G.; MALHOTRA, A.; NEMATI, S. Artificial intelligence sepsis prediction algorithm learns to say “I don't know”. **npj Digital Medicine**, v. 4, n. 1, p. 1–9, 2021. Springer US. Disponível em: <<http://dx.doi.org/10.1038/s41746-021-00504-6>>.

SHIH, C. C.; LU, C. J.; CHEN, G. DEN; CHANG, C. C. Risk prediction for early chronic kidney disease: Results from an adult health examination program of 19,270 individuals. **International Journal of Environmental Research and Public Health**, v. 17, n. 14, p. 1–11, 2020.

SHIMKO, M. S. et al. Long-term complications of conduit urinary diversion. **Journal of Urology**, v. 185, n. 2, p. 562-567, fev. 2011. Disponível em: <http://www.jurology.com/doi/10.1016/j.juro.2010.09.096>. Acesso em: 20 ago. 2024.

SILVA, Ivan Nunes da; SPATTI, Danilo Hernane; FLAUZINO, Rogerio Andrade. *Redes neurais artificiais para engenharia e ciências aplicadas: curso prático*. 2. ed. São Paulo: Artliber, 2016.

SILVEIRA, A. A. S.; GUIMARÃES, N. F. C.; SOUSA, L. V. DE; SOUZA, M. G. G. R. DE; SILVA, J. DE P. Aspectos Fisiopatológicos Da Covid-19. **Pandemia da COVID-19: Uma Visão Multidisciplinar**, v. 3, 2021.

TANG, X.; LIESKE, J. C. Acute and chronic kidney injury in nephrolithiasis. **Current Opinion in Nephrology and Hypertension**, [s.l.], v. 23, n. 4, p. 385-390, jul. 2014. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4096690/>. Acesso em: 20 ago. 2023.

TANIOS, N.; WAGNER, M.; TONY, M.; et al. Which criteria are considered in healthcare decisions? Insights from an international survey of policy and clinical decision makers. **International Journal of Technology Assessment in Health Care**, v. 29, n. 4, p. 456–465, 2013.

TARIQ, A.; CELI, L. A.; NEWSOME, J. M.; et al. Patient-specific COVID-19 resource utilization prediction using fusion AI model. **npj Digital Medicine**, v. 4, n. 1, p. 1–9, 2021. Springer US. Disponível em: <<http://dx.doi.org/10.1038/s41746-021-00461-0>>.

THOKALA, P.; DEVLIN, N.; MARSH, K.; et al. Multiple criteria decision analysis for health care decision making - An introduction: Report 1 of the ISPOR MCDA Emerging Good Practices Task Force. **Value in Health**, v. 19, n. 1, p. 1–13, 2016. Elsevier. Disponível em: <<http://dx.doi.org/10.1016/j.jval.2015.12.003>>.

TOSTES, M. F.; COVRE, E. R.; FERNANDES, C. A. Access to surgical assistance: challenges and perspectives. **Revista Latino-Americana de Enfermagem**, v. 24, p. e2677, 2016.

TRICCO, A. C.; LILLIE, E.; ZARIN, W.; et al. PRISMA extension for scoping reviews (PRISMA-ScR): Checklist and explanation. **Annals of Internal Medicine**, v. 169, n. 7, p. 467–473, 2018.

TUNNEY, M. Comparative assessment of ureteral stent biomaterial encrustation. **Biomaterials**, v. 17, n. 15, p. 1541-1546, 1996.

TÜRK, C. et al. EAU guidelines on interventional treatment for urolithiasis. **European Urology**, v. 69, n. 3, p. 475-482, 1 mar. 2016a.

TÜRK, C. et al. EAU guidelines on diagnosis and conservative management of urolithiasis. **European Urology**, v. 69, n. 3, p. 468-474, 1 mar. 2016b.

TUROFF, M.; LINSTONE, H. A. **The Delphi Method: Techniques and**

Applications. 2002.

UNSAL, A. et al. Prediction of morbidity and mortality after percutaneous nephrolithotomy by using the Charlson Comorbidity Index. **Urology**, v. 79, n. 1, p. 55-60, jan. 2012. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0090429511006935>. Acesso em: 20 ago. 2023.

URIBARRI, J. Chronic kidney disease and kidney stones. **Current Opinion in Nephrology and Hypertension**, v. 29, n. 2, p. 237-242, mar. 2020.

WANG, S.; DONG, D.; LI, L.; et al. A Deep Learning Radiomics Model to Identify Poor Outcome in COVID-19 Patients with Underlying Health Conditions: A Multicenter Study. **IEEE Journal of Biomedical and Health Informatics**, v. 25, n. 7, p. 2353–2362, 2021. IEEE.

WEE, C. K. et al. Triaging Medical Referrals Based on Clinical Prioritisation Criteria Using Machine Learning Techniques. **International Journal of Environmental Research and Public Health**, v. 19, n. 12, p. 7384, 16 jun. 2022.

WIJAYA, W. Saputra; IRDAM, G. A.; RAHMAN, F. Predicting parameters of renal function recoverability after obstructive uropathy treatment in adults. **Acta Medica Indonesiana - The Indonesian Journal of Internal Medicine**, v. 54, 2022.

WRIGHT, J. T. C.; GIOVINAZZO, R. A. Delphi: uma ferramenta de apoio ao planejamento prospectivo. **Caderno de Pesquisas em Administração**, v. 1, p. 54–65, 2000. Disponível em: <<http://www.fundacaofia.com.br/profuturo/Uploads/Documents/Artigos/art50.htm>>.

YAN, L.; ZHANG, H.-T.; GONCALVES, J.; et al. An interpretable mortality prediction model for COVID-19 patients. **Nature Machine Intelligence**, v. 2, n. 5, p. 283–288, 2020. Springer US. Disponível em: <<http://dx.doi.org/10.1038/s42256-020-0180-7>>.

YAZICI, E. et al. Prioritizing Individuals Who Will Have Covid-19 Vaccine with Multi-Criteria Decision Making Methods. **GAZI UNIVERSITY JOURNAL OF SCIENCE**, 13 jun. 2022.

YOO, M. J. et al. Approach to nephrostomy tubes in the emergency department. **American Journal of Emergency Medicine**, v. 50, p. 592-596, dez. 2021.

ZADEH, L. A. Fuzzy Sets. **Information and Control**, v. 353, p. 1562–1569, 1965.

ZHANG, K. P.; ZHANG, Y.; CHAO, M. Which is the best way for patients with ureteral obstruction? Percutaneous nephrostomy versus double J stenting. **Medicine**, v. 101, n. 45, p. e31194, 11 nov. 2022.

GLOSSÁRIO

ABORDAGEM NEUTROSÓFICA DE MULTICRITÉRIO – a lógica neutrosófica é uma extensão da lógica clássica e da lógica fuzzy, a qual lida com incertezas de uma forma mais abrangente. Na abordagem neutrosófica de multicritério, as informações são representadas por verdadeiro, falso e indeterminado, permitindo uma maior flexibilidade em situações incertas. Utiliza-se essa abordagem em problemas que possuem múltiplos critérios a serem considerados simultaneamente.

ACURÁCIA – métrica usada para avaliar o desempenho de um modelo de aprendizado de máquina. Essa métrica consiste na proporção de previsões corretas em relação ao número total de previsões realizadas pelo modelo a ser avaliado.

ADAPTIVE BOOSTING (ADABOOST) – algoritmo de *ensemble learning* que utiliza uma combinação de múltiplos modelos fracos com o objetivo de obter um modelo forte e preciso.

ADAPTIVE SYNTHETIC SAMPLING (ADASYN) – técnica de sobreamostragem utilizada para equilibrar conjuntos de dados desbalanceados em modelos de aprendizado de máquina. Essa técnica cria exemplos sintéticos numa classe com menor número de dados, com o intuito de melhorar a precisão do modelo.

ANÁLISE DISCRIMINANTE LINEAR (LDA) – método estatístico utilizado para separar grupos de dados, classificar novos dados e reduzir a quantidade de variáveis sem perder informações importantes.

ANÁLISE DE VARIÂNCIA (ANOVA) – teste estatístico utilizado para comparar as médias de três ou mais grupos e verificar se existem diferenças significativas entre elas.

APRENDIZADO DE MÁQUINA EXTREMO (EXTREME LEARNING MACHINE - ELM) – é uma técnica de aprendizado de máquina muito usada em redes neurais artificiais. O ELM treina apenas a camada de saída de uma rede neural, enquanto os pesos das conexões entre as camadas ocultas são definidos aleatoriamente, tornando o processo mais rápido.

ÁREA SOB A CURVA (AUC) – métrica usada para medir o desempenho de modelos de classificação binária. A AUC é comumente associada à curva ROC (Receiver Operating Characteristic), que é um gráfico que relaciona a taxa de verdadeiros positivos com a taxa de falsos positivos, para diferentes limiares de decisão.

ÁRVORE DE CLASSIFICAÇÃO E REGRESSÃO (CART) – árvore de decisão binária, em que cada nó gera apenas duas ramificações.

ÁRVORE DE DECISÃO (DECISION TREE) – algoritmo de aprendizado de máquina usado para classificação e regressão. Ela organiza os dados em uma estrutura hierárquica em forma de árvore, onde cada nó interno representa uma pergunta ou condição e gera ramificações, cada ramo indica uma possível resposta, e cada nó folha contém a previsão final do modelo.

AVALIAÇÃO BASEADA NA DISTÂNCIA DA SOLUÇÃO MÉDIA (EDAS) – técnica de decisão multicritério que avalia cada alternativa de acordo com a sua proximidade de um valor médio ideal. Além disso, calcula pontuações positivas quando a solução está acima do valor médio e negativas se estiver abaixo, para determinar a melhor solução, a qual mais se aproxima da solução ideal.

BALANCEAMENTO – técnica para ajustar a distribuição dos dados, corrigindo desequilíbrios, com o objetivo de evitar viés em um modelo de aprendizado de máquina.

COEFICIENTE DE CORRELAÇÃO DE SPEARMAN – medida estatística que avalia a relação entre duas variáveis de uma forma não linear. A análise é feita verificando a ordem (ou posição) dos dados, em vez de seus valores exatos.

COEFICIENTE DE PONTUAÇÃO DE DICE – métrica estatística que mede a similaridade entre dois conjuntos.

CONDITIONAL GENERATIVE ADVERSARIAL NETWORK (CTGAN) – redes neurais usadas para gerar novos dados a partir de uma distribuição de probabilidade. É uma variação das *Generative Adversarial Networks* (GANs).

CONJUNTO DE EMPILHAMENTO ADAPTATIVO – é uma técnica de aprendizado de máquina que une vários modelos para melhorar a precisão das previsões. Essa técnica se baseia no método Stacking (empilhamento), na qual inicialmente diferentes

algoritmos são treinados separadamente e após suas previsões são combinadas por um modelo principal que gera a previsão final, chamado meta-modelo.

CORONAVIRUS DISEASE 2019 (COVID-19) – doença infecciosa causada pelo coronavírus SARS-CoV-2. Seu início ocorreu em dezembro de 2019, na China, e se espalhou pelo mundo, resultando em uma pandemia.

DELAY RATIO – taxa de atraso que avalia o impacto dos atrasos, comparando o tempo real de execução com o tempo planejado, para a realização de uma tarefa ou evento.

DEMPSTER-SHAFER – modelo matemático utilizado para lidar com incertezas e fusão de informações na tomada de decisão. Nesse modelo é possível trabalhar com graus de crenças, atribuído a diversas hipóteses, sem que seja conhecidas probabilidades exatas.

EMBEDDABLE AI AND STATE-BASED UNDERSTANDING LOGIC (EASUL) – ferramenta que combina inteligência artificial (IA) incorporável (embeddable) e lógica baseada em estados. Ela ajuda a criar sistemas mais inteligentes que auxiliam na tomada de decisões.

ENSEMBLE LEARNING – técnica de aprendizado de máquina que combina múltiplos modelos visando melhorar a precisão e a robustez das previsões.

ESCALA BEST-WORST – método de avaliação multicritério utilizado para classificar e priorizar alternativas, no qual o participante seleciona o critério mais importante (Best) e o menos importante (Worst) dentro de um conjunto de opções.

ESPECIFICIDADE – métrica de avaliação de modelos de classificação que mede a proporção de verdadeiros negativos identificados corretamente.

EXTREMELY RANDOMIZED TREES (EXTRA TREES) – algoritmo de aprendizado de máquina que utiliza várias árvores de decisão geradas de forma aleatória durante o treinamento.

FAST.AI – biblioteca de aprendizado profundo que facilita a construção e o treinamento de modelos de redes neurais, tornando o processo mais acessível.

FEATURE_IMPORTANCES – atributo em modelos de aprendizado de máquina que indica a importância relativa de cada característica (ou variável), mostrando quanto cada uma contribui para a decisão do modelo.

GAUSSIAN NAIVE BAYES (GNB) – variação do algoritmo Naive Bayes, utilizado para classificação. Esse método assume que as variáveis independentes seguem uma distribuição normal (Gaussiana).

GRADIENT BOOSTED TREES (XGBOOST) – algoritmo de aprendizado de máquina que combina várias árvores de decisão fracas com a intenção de formar um modelo forte. A ideia do algoritmo segue o conceito de *boosting*, no qual cada árvore busca corrigir erros de árvores anteriores, de forma sequencial.

GRADIENTE DESCENDENTE (RLM) – método de otimização utilizado para ajustar os coeficientes de um modelo de regressão linear, com o objetivo de minimizar a função de erro. Nesse método, os parâmetros são ajustados iterativamente até que a diferença entre as previsões e os valores reais seja a menor possível.

GRADIENT-WEIGHTED CLASS ACTIVATION MAPPING (GRAD-CAM) – técnica utilizada para interpretar e visualizar redes neurais convolucionais, destacando as regiões da imagem que mais influenciam a decisão do modelo, permitindo entender quais características são mais relevantes para a classificação.

INFORMAÇÃO MÚTUA – medida estatística que avalia a dependência entre duas variáveis, quantificando o quanto o conhecimento de uma variável diminui a incerteza sobre a outra.

INTELIGÊNCIA AUMENTADA – conceito relacionado ao uso de tecnologias de inteligência artificial (IA) para melhorar as habilidades humanas.

K-MEANS – algoritmo de clusterização utilizado para separar dados em diferentes clusters (grupos), de forma que cada grupo tenha características semelhantes.

K-NEAREST NEIGHBORS (KNN) – é um algoritmo de aprendizado supervisionado usado para classificação e regressão. Ele atribui um novo ponto a uma categoria, de acordo com as categorias dos vizinhos mais próximos.

LIMIARIZAÇÃO – técnica de processamento de dados que separa um conjunto de dados em dois grupos com base em um valor de corte (limiar). Assim, os valores são classificados em dois grupos: acima e abaixo do limiar.

LITÍASE URINÁRIA – condição em que se formam cálculos (pedras) no sistema urinário (rins, ureteres, bexiga e uretra), devido ao acúmulo de substâncias como cálcio, ácido úrico ou oxalato na urina.

MATRIZ DE CONFUSÃO – tabela que organiza as previsões de um modelo, classificando-as em verdadeiros positivos, falsos positivos, verdadeiros negativos e falsos negativos, com o objetivo de avaliar o desempenho de um modelo de classificação.

MEMÓRIA DE LONGO PRAZO (MLP) – tipo de rede neural recorrente (RNN) desenvolvida para tratar o problema de desvanecimento do gradiente, que acontece quando os valores dos gradientes (as alterações feitas nos pesos da rede durante o aprendizado) ficam muito pequenos à medida que são propagados de volta pelas camadas da rede.

MÉTODO DE CLASSIFICAÇÃO DE COMPROMISSO MULTICRITÉRIO (VIKOR) – método de decisão multicritério que avalia a proximidade das alternativas com a solução ideal, buscando um equilíbrio entre as diferentes opções.

PREFERENCE RANKING ORGANIZATION METHOD FOR ENRICHMENT EVALUATION (PROMETHEE) – método de tomada de decisão multicritério usado para classificar alternativas, levando em consideração as preferências do decisor.

MÉTODO KAPLAN-MEIER – técnica estatística utilizada para estimar a probabilidade de sobrevivência de uma população ao longo do tempo, muito utilizada em estudos de análise de sobrevivência, como aqueles que investigam a taxa de sobrevivência de pacientes.

MÉTODOS MULTICRITÉRIO DE APOIO À DECISÃO (MMAD) – métodos que auxiliam na tomada de decisão em situações com múltiplos critérios, os quais são, muitas vezes, conflitantes.

MIN-MAX REGRET – abordagem de tomada de decisão utilizada em situações de incerteza. O objetivo dessa abordagem é minimizar o arrependimento, que se refere à diferença entre o resultado obtido de uma determinada alternativa e o melhor resultado possível.

NAIVE BAYES – algoritmo de classificação probabilística baseado no Teorema de Bayes, que calcula a probabilidade de uma classe (categoria) com base nas características ou atributos dos dados de entrada. Ele assume que as variáveis preditoras são independentes entre si, simplificando o problema e tornando o cálculo mais eficiente.

OTIMIZAÇÃO MULTI-OBJETIVO COM BASE NA ANÁLISE DE RAZÃO (MOORA) – abordagem de decisão multicritério que compara alternativas normalizando os dados de cada critério, calcula razões entre os valores normalizados e, em seguida, gera uma pontuação para classificar as alternativas, buscando a melhor opção dentre todos os critérios.

OVERFITTING – ocorre quando um modelo de aprendizado de máquina apresenta um bom desempenho no conjunto de treinamento, mas tem um desempenho ruim ao generalizar para novos dados, como os do conjunto de teste. Isso acontece porque o modelo se ajusta excessivamente aos detalhes e ao "ruído" dos dados de treinamento, em vez de capturar padrões gerais.

ESTIMADOR DE JANELA DE PARZEN (PARZEN WINDOW ESTIMATOR) – técnica não paramétrica usada para estimar a função de densidade de probabilidade de uma variável aleatória, com base em uma amostra de dados.

PIPELINES – sequências de etapas organizadas que ajudam a automatizar o processo de preparação de dados e treinamento de modelos de aprendizado de máquina.

PONTUAÇÃO DE BRIER – mede a precisão das previsões probabilísticas de um modelo, comparando as probabilidades previstas com os resultados observados. Assim, quanto menor o valor da pontuação, mais precisas são as previsões feitas pelo modelo.

PONTUAÇÃO F1 – métrica calculada como a média harmônica entre precisão e *recall*, utilizada para avaliar o desempenho de modelos de classificação, especialmente em casos em que há desequilíbrio entre as classes.

PRECISÃO – métrica que calcula a proporção de previsões positivas corretas em relação ao total de previsões positivas do modelo, sendo especialmente utilizada na avaliação de modelos de classificação quando a redução de falsos positivos é importante.

PROCESSO ANALÍTICO HIERÁRQUICO EM MÚLTIPLAS CAMADAS (MLAHP) – extensão do Processo Analítico Hierárquico (AHP) que organiza critérios e subcritérios em múltiplos níveis, facilitando a análise de problemas complexos e auxiliando na tomada de decisão.

PROCESSO ANALÍTICO DE REDE (ANP) – extensão do Processo Analítico Hierárquico (AHP) que considera a interdependência entre critérios e alternativas. Em vez de uma estrutura hierárquica, o ANP organiza os elementos do problema em uma rede interconectada, permitindo que critérios e alternativas influenciem uns aos outros na tomada de decisão.

PYTORCH – biblioteca de aprendizado profundo de código aberto, utilizada para criar e treinar redes neurais, proporcionando flexibilidade e bom desempenho na construção e implementação dos modelos.

RADIÔMICA – técnica utilizada para extrair grandes quantidades de características quantitativas de imagens médicas, como tomografias e ressonâncias magnéticas, com o intuito de auxiliar na tomada de decisão na área da saúde.

RANDOM FOREST – método de aprendizado de máquina que usa várias árvores de decisão para fazer previsões. Cada árvore é treinada com uma parte diferente dos dados e a previsão final é feita pela média das previsões das árvores (em regressão) ou pela maioria das decisões das árvores (em classificação).

REDE NEURAL CONVOLUCIONAL – tipo de rede neural que detecta padrões e características, como bordas e formas, auxiliando em tarefas como reconhecimento de objetos e classificação de imagens.

REDE NEURAL CONVOLUCIONAL DE DUAS CABEÇAS – tipo de rede neural que analisa uma imagem de duas maneiras diferentes ao mesmo tempo. A primeira parte da rede aprende padrões básicos, e depois cada "cabeça" foca em um tipo de informação, auxiliando na resolução de tarefas mais complexas.

RECALL (OU SENSIBILIDADE) – métrica que mede a proporção de verdadeiros positivos de um modelo de classificação em relação ao total de casos positivos reais.

RECEIVER OPERATING CHARACTERISTIC (ROC) – gráfico em forma de curva que ilustra a taxa de verdadeiros positivos e a taxa de falsos positivos em diferentes limiares de decisão em um modelo de classificação, especialmente em classificação binária.

RECURSIVE FEATURE ELIMINATION (RFE) – técnica utilizada para selecionar as variáveis mais importantes em um modelo de aprendizado de máquina, com o objetivo de melhorar o desempenho do modelo.

REGRESSÃO LINEAR – modelo estatístico que ajusta uma reta que melhor descreva a relação entre uma variável dependente (resposta) e uma ou mais variáveis independentes (preditoras).

REGRESSÃO LOGÍSTICA – modelo estatístico usado para prever a probabilidade de um evento binário ocorrer, com base em uma ou mais variáveis independentes.

RISK-CRITERIA SCORE – abordagem que avalia e prioriza alternativas com base em critérios de risco, levando em consideração a gravidade, probabilidade e impacto dos riscos. Os critérios recebem uma pontuação para comparar as alternativas de acordo com o nível de risco envolvido.

SCIKIT-LEARN – biblioteca de aprendizado de máquina em Python, que oferece ferramentas para análise e modelagem de dados.

SHELL EXPERT – software de análise de risco que utiliza técnicas de simulação e modelos estatísticos para avaliar incertezas e auxiliar na tomada de decisões em projetos e operações.

SOBREAMOSTRAGEM – técnica que visa equilibrar classes em um conjunto de dados desbalanceado, aumentando o número de exemplos de uma classe menor, evitando que o modelo favoreça a classe com maior quantidade de exemplos.

SUPPORT VECTOR MACHINE (SVM) – algoritmo de aprendizado supervisionado usado para classificar ou prever dados. O algoritmo funciona com a obtenção de uma linha (ou plano, em casos mais complexos) que separa as diferentes categorias de dados, garantindo que a distância entre as categorias seja a maior possível.

SYNTHETIC MINORITY OVER-SAMPLING TECHNIQUE (SMOTE) – técnica de sobreamostragem que trata o desequilíbrio de classes em problemas de classificação, criando exemplos sintéticos para a classe com uma menor quantidade de exemplos.

TÉCNICA PARA ORDENAÇÃO POR SIMILARIDADE COM A SOLUÇÃO IDEAL (TOPSIS) – método de decisão multicritério que classifica alternativas com base em sua proximidade à solução ideal, escolhendo a melhor opção entre várias, levando em conta a distância das alternativas em relação à melhor e à pior solução possível.

TESTE DE GEHAN-BRESLOW-WILCOXON – variação do teste de log-rank, usado para comparar curvas de sobrevivência entre grupos. Ele atribui mais peso aos eventos iniciais e é útil em estudos de sobrevida com censura de dados, onde alguns participantes não experienciam o evento ou saem do estudo antes do fim.

TESTE DE LOG-RANK – teste estatístico utilizado para analisar se as diferenças nas curvas de sobrevivência dos grupos são estatisticamente significativas em estudos de sobrevida.

TESTE EXATO DE FISHER – teste usado para verificar se duas variáveis categóricas estão associadas em uma tabela 2x2. O teste é útil quando as frequências são pequenas demais para usar outros testes, como o Qui-quadrado. Ele calcula a chance exata de obter os resultados observados, caso não haja relação entre as variáveis.

TESTE QUI-QUADRADO – teste estatístico usado para verificar a associação entre duas variáveis categóricas, comparando as frequências observadas em uma tabela de contingência, sob a hipótese de que não há relação entre as variáveis.

TESTE T – técnica estatística usada para comparar as médias de dois grupos e verificar se existe uma diferença significativa entre elas.

TESTE U DE MANN-WHITNEY – teste estatístico não paramétrico utilizado para comparar duas amostras independentes e avaliar se elas têm distribuições distintas. Esse teste é utilizado quando os dados não seguem uma distribuição normal.

THRESHOLD-BASED – abordagem em que a decisão ou classificação é feita com base em um valor de limite (limiar) pré-definido.

TEXT SIMILARITY (SIMILARIDADE DE TEXTO) – é a medida do grau de semelhança entre dois ou mais textos.

VALIDAÇÃO CRUZADA (K-FOLD) – método de avaliação de modelos em que os dados são divididos em k partes. O modelo é treinado k vezes, usando uma parte diferente como teste a cada vez, e a média dos resultados é calculada para avaliar o desempenho do modelo, ajudando a reduzir o viés e melhorar a generalização.

APÊNDICE 1 – RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA
ABORDAGEM DE REDES NEURAIS

Neste APÊNDICE estão contidos os resultados dos experimentos computacionais apresentados nas FIGURA de 24 a 75, apresentando um resumo estatístico e um gráfico de linhas para o erro (perda) e para a acurácia de cada experimento realizado. Os experimentos com as configurações apresentadas abaixo, foram realizadas somente uma vez, pois os experimentos iniciais também consideraram o número de épocas igual a 300 e a taxa de aprendizagem 0,001.

Para a RN_1, a configuração arquitetura 1, função “elu”, 300 épocas e taxa de aprendizagem 0,001. Para a RN_21 e RN_22, a configuração arquitetura 2, função “elu”, 300 épocas e taxa de aprendizagem 0,001. Para a RN_23, a configuração arquitetura 2, função “leaky relu”, 300 épocas e taxa de aprendizagem 0,001.

PRIMEIRA PARTE (RN_1)

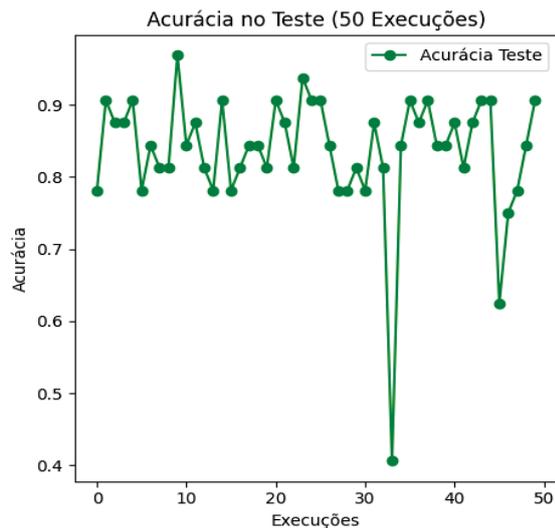
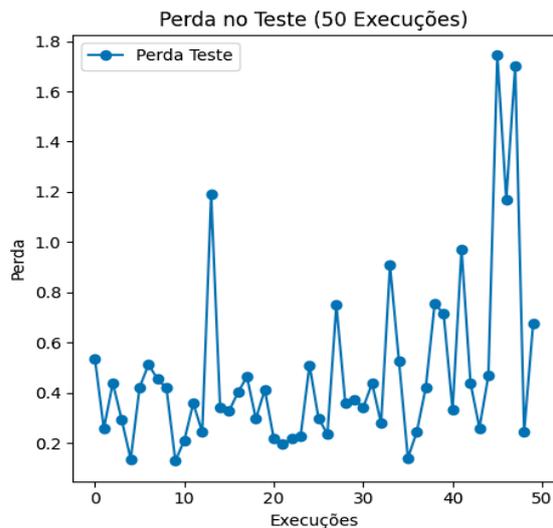
FIGURA 24 – RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_1, ARQUI_1 E FUNÇÃO RELU

Arqui_1 e Relu - Erro:

Estatística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 0.480307	Média dos erros
2	std 0.351928	Desvio padrão
3	min 0.129061	Valor mínimo
4	25% 0.258062	Primeiro quartil (25%)
5	50% 0.387558	Mediana (50%)
6	75% 0.512596	Terceiro quartil (75%)
7	max 1.744498	Valor máximo

Arqui_1 e Relu - Acurácia:

Estatística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.836250	Média das acurácias
2	std 0.085770	Desvio padrão
3	min 0.406250	Valor mínimo
4	25% 0.812500	Primeiro quartil (25%)
5	50% 0.843750	Mediana (50%)
6	75% 0.898438	Terceiro quartil (75%)
7	max 0.968750	Valor máximo



FONTE: A autora (2024).

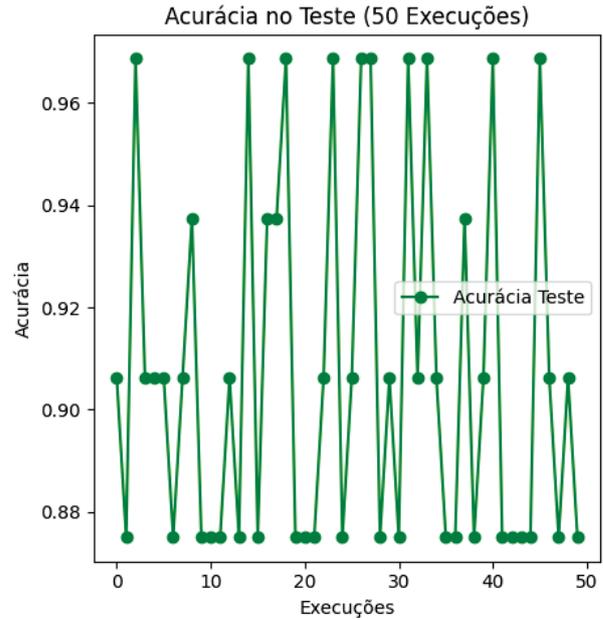
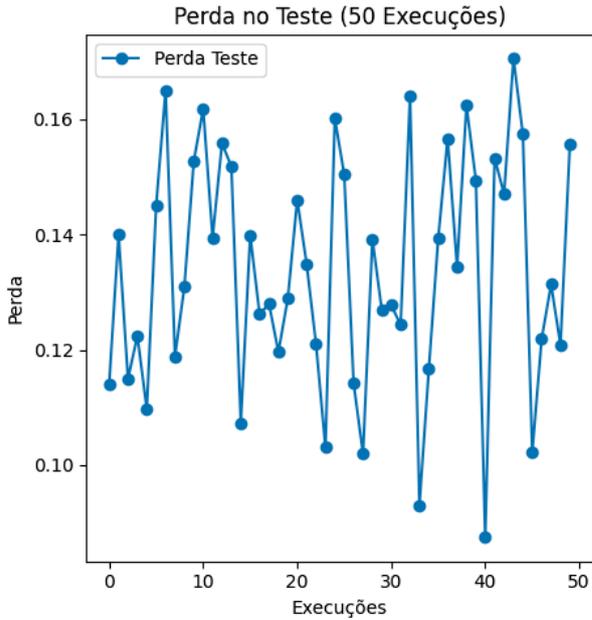
FIGURA 25 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_1, ARQUI_1 E FUNÇÃO ELU

Arqui_1 e Elu - Erro:

Estatística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 0.133746	Média dos erros
2	std 0.020499	Desvio padrão
3	min 0.087462	Valor mínimo
4	25% 0.119955	Primeiro quartil (25%)
5	50% 0.132904	Mediana (50%)
6	75% 0.151468	Terceiro quartil (75%)
7	max 0.170597	Valor máximo

Arqui_1 e Elu - Acurácia:

Estatística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.907500	Média das acurácias
2	std 0.036246	Desvio padrão
3	min 0.875000	Valor mínimo
4	25% 0.875000	Primeiro quartil (25%)
5	50% 0.906250	Mediana (50%)
6	75% 0.937500	Terceiro quartil (75%)
7	max 0.968750	Valor máximo



FONTE: A autora (2024).

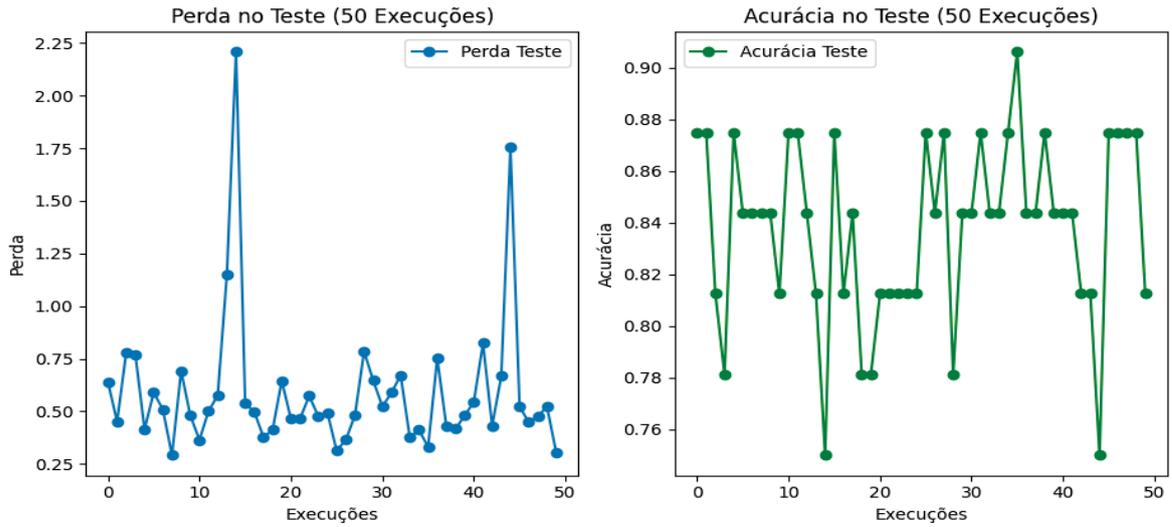
FIGURA 26 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_1, ARQUI_1 E FUNÇÃO LEAKY RELU

Arqui_1 e Leaky ReLU - Erro:

Estatística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 0.588219	Média dos erros
2	std 0.331265	Desvio padrão
3	min 0.291280	Valor mínimo
4	25% 0.428207	Primeiro quartil (25%)
5	50% 0.499162	Mediana (50%)
6	75% 0.643707	Terceiro quartil (75%)
7	max 2.209288	Valor máximo

Arqui_1 e Leaky ReLU - Acurácia:

Estatística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.838125	Média das acurácias
2	std 0.035541	Desvio padrão
3	min 0.750000	Valor mínimo
4	25% 0.812500	Primeiro quartil (25%)
5	50% 0.843750	Mediana (50%)
6	75% 0.875000	Terceiro quartil (75%)
7	max 0.906250	Valor máximo



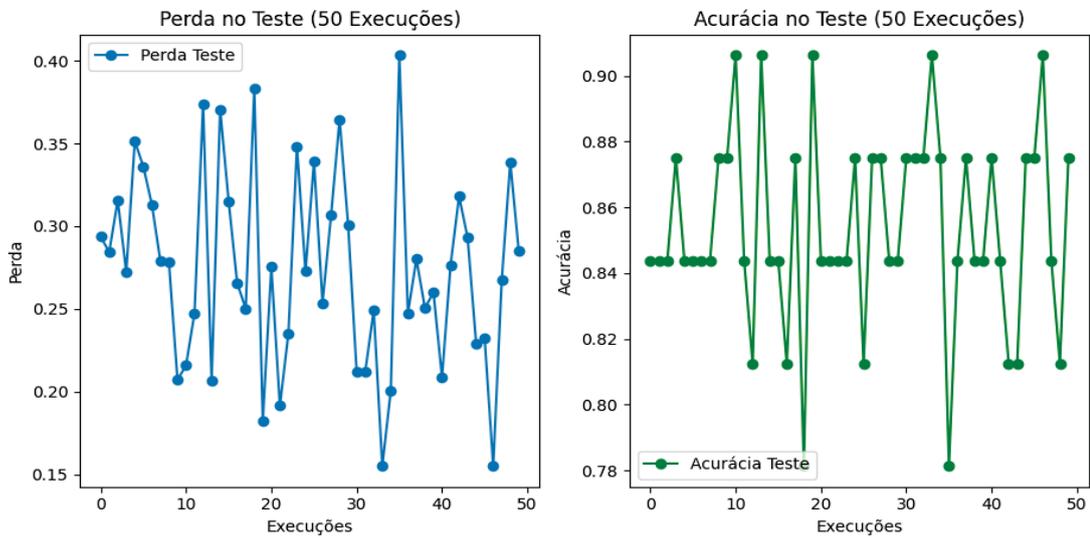
FONTE: A autora (2024).

FIGURA 27 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_1, ARQUI_2 E FUNÇÃO RELU

Arqui_2 e Relu - Erro:

Arqui_2 e Relu - Acurácia:

Estadística	Erro	Descrição	Estadística	Acurácia	Descrição
0	count 50.000000	Número de repetições	0	count 50.000000	Número de repetições
1	mean 0.273980	Média dos erros	1	mean 0.853750	Média das acurácias
2	std 0.059248	Desvio padrão	2	std 0.029907	Desvio padrão
3	min 0.154918	Valor mínimo	3	min 0.781250	Valor mínimo
4	25% 0.232750	Primeiro quartil (25%)	4	25% 0.843750	Primeiro quartil (25%)
5	50% 0.273945	Mediana (50%)	5	50% 0.843750	Mediana (50%)
6	75% 0.314422	Terceiro quartil (75%)	6	75% 0.875000	Terceiro quartil (75%)
7	max 0.403330	Valor máximo	7	max 0.906250	Valor máximo



FONTE: A autora (2024).

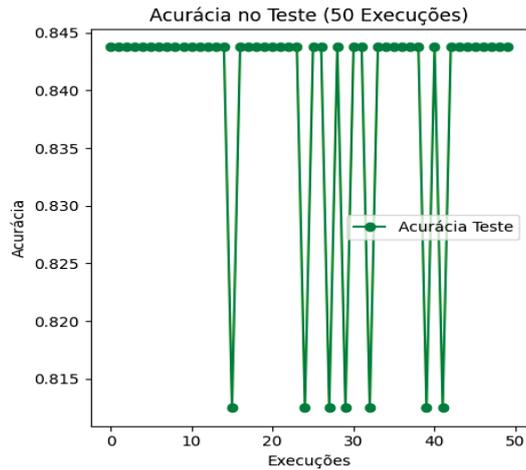
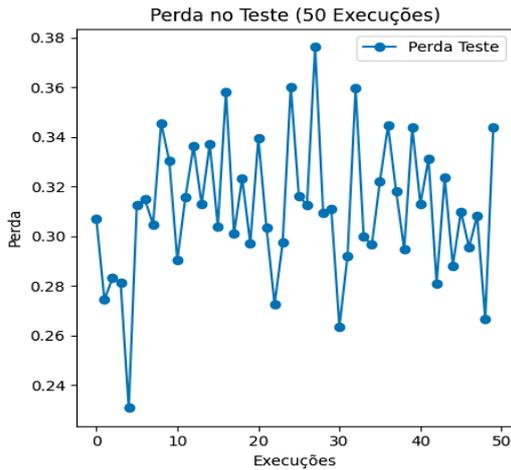
FIGURA 28 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_1, ARQUI_2 E FUNÇÃO ELU

Arqui_2 e Elu - Erro:

Estadística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 0.311070	Média dos erros
2	std 0.027875	Desvio padrão
3	min 0.230760	Valor mínimo
4	25% 0.295774	Primeiro quartil (25%)
5	50% 0.310344	Mediana (50%)
6	75% 0.328675	Terceiro quartil (75%)
7	max 0.376267	Valor máximo

Arqui_2 e Elu - Acurácia:

Estadística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.839375	Média das acurácias
2	std 0.010953	Desvio padrão
3	min 0.812500	Valor mínimo
4	25% 0.843750	Primeiro quartil (25%)
5	50% 0.843750	Mediana (50%)
6	75% 0.843750	Terceiro quartil (75%)
7	max 0.843750	Valor máximo



FONTE: A autora (2024).

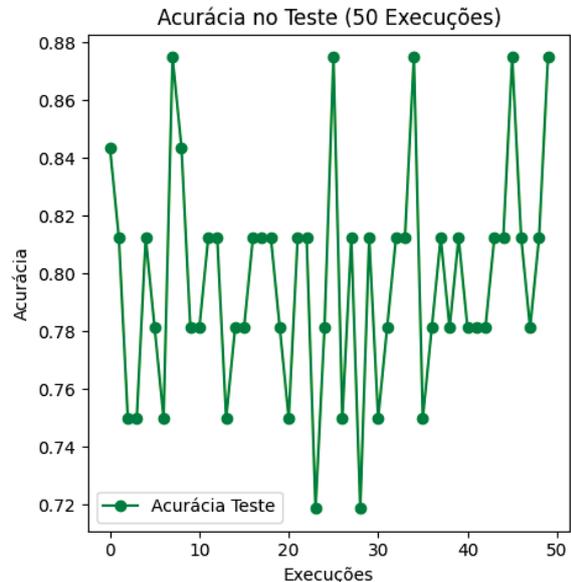
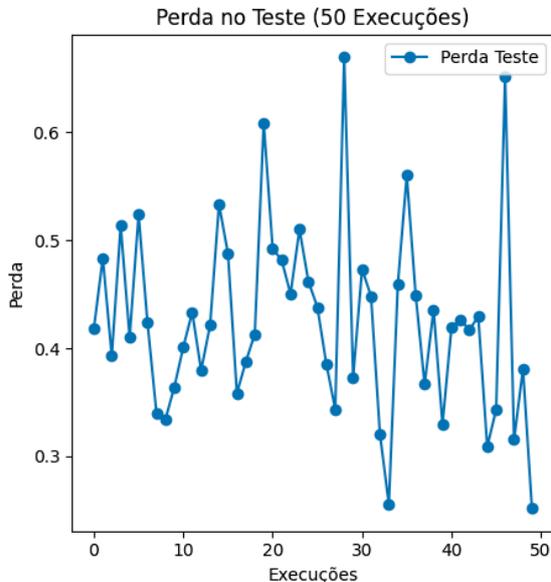
FIGURA 29 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_1, ARQUI_2 E FUNÇÃO LEAKY RELU

Arqui_2 e Leaky ReLU - Erro:

Estadística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 0.425636	Média dos erros
2	std 0.087859	Desvio padrão
3	min 0.251754	Valor mínimo
4	25% 0.368289	Primeiro quartil (25%)
5	50% 0.420258	Mediana (50%)
6	75% 0.470551	Terceiro quartil (75%)
7	max 0.669772	Valor máximo

Arqui_2 e Leaky ReLU - Acurácia:

Estadística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.797500	Média das acurácias
2	std 0.038528	Desvio padrão
3	min 0.718750	Valor mínimo
4	25% 0.781250	Primeiro quartil (25%)
5	50% 0.812500	Mediana (50%)
6	75% 0.812500	Terceiro quartil (75%)
7	max 0.875000	Valor máximo



FONTE: A autora (2024).

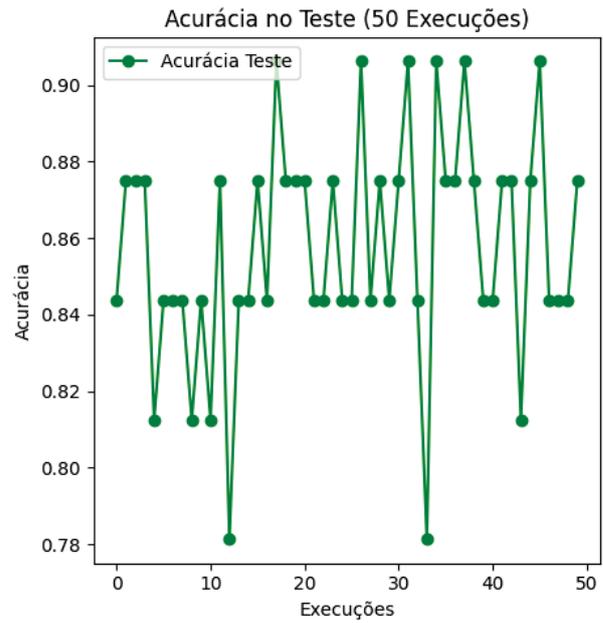
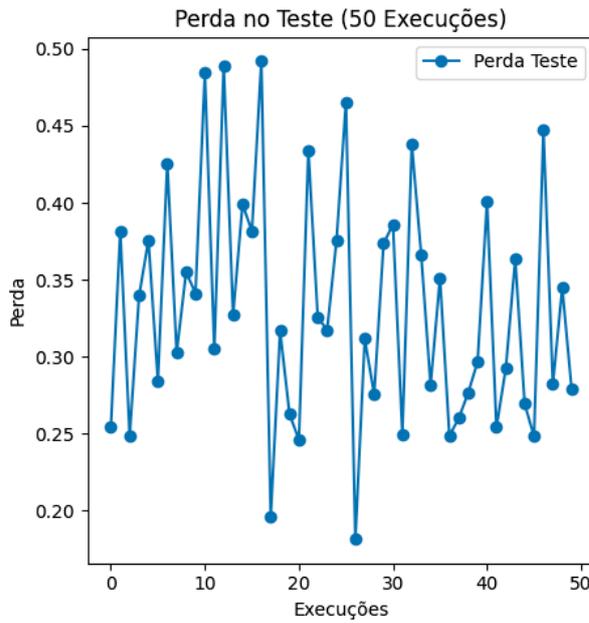
FIGURA 30 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_1, ARQUI_3 E FUNÇÃO RELU

Arqui_3 e Relu - Erro:

Estadística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 0.332053	Média dos erros
2	std 0.076346	Desvio padrão
3	min 0.181249	Valor mínimo
4	25% 0.275697	Primeiro quartil (25%)
5	50% 0.321415	Mediana (50%)
6	75% 0.380126	Terceiro quartil (75%)
7	max 0.492148	Valor máximo

Arqui_3 e Relu - Acurácia:

Estadística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.857500	Média das acurácias
2	std 0.029720	Desvio padrão
3	min 0.781250	Valor mínimo
4	25% 0.843750	Primeiro quartil (25%)
5	50% 0.843750	Mediana (50%)
6	75% 0.875000	Terceiro quartil (75%)
7	max 0.906250	Valor máximo



FONTE: A autora (2024).

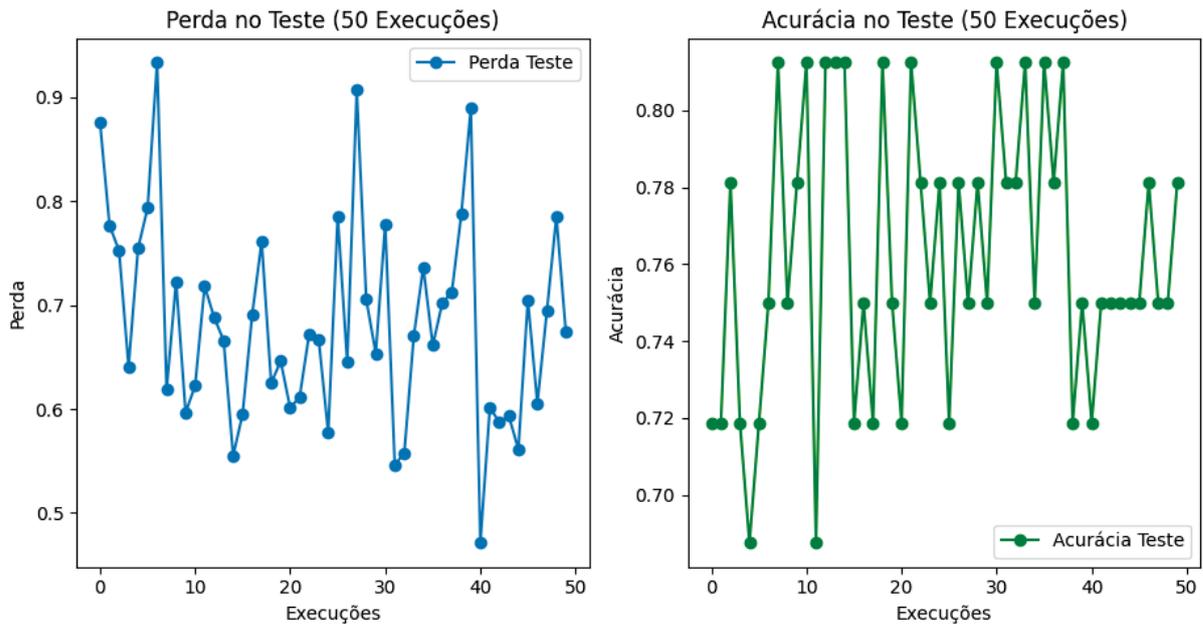
FIGURA 31 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_1, ARQUI_3 E FUNÇÃO EL

Arqui_3 e Elu - Erro:

Estadística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 0.683545	Média dos erros
2	std 0.098504	Desvio padrão
3	min 0.471089	Valor mínimo
4	25% 0.607028	Primeiro quartil (25%)
5	50% 0.671241	Mediana (50%)
6	75% 0.748486	Terceiro quartil (75%)
7	max 0.933644	Valor máximo

Arqui_3 e Elu - Acurácia:

Estadística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.761875	Média das acurácias
2	std 0.036208	Desvio padrão
3	min 0.687500	Valor mínimo
4	25% 0.750000	Primeiro quartil (25%)
5	50% 0.750000	Mediana (50%)
6	75% 0.781250	Terceiro quartil (75%)
7	max 0.812500	Valor máximo



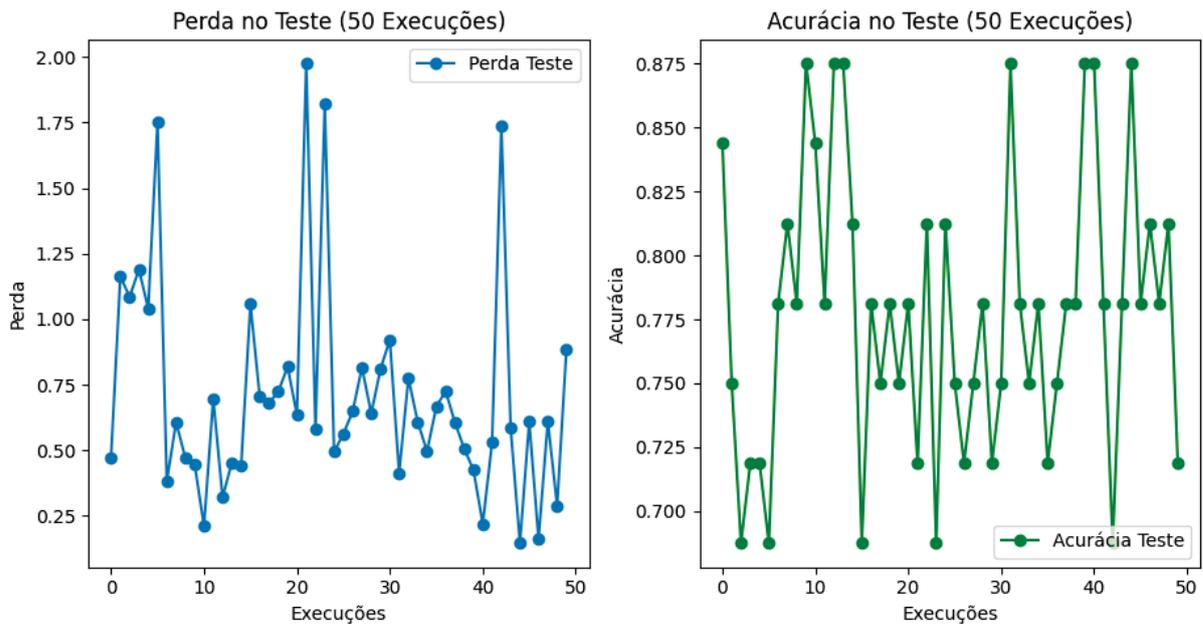
FONTE: A autora (2024).

FIGURA 32 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_1, ARQUI_3 E FUNÇÃO LEAKY RELU

Arqui_3 e Leaky ReLU - Erro:

Arqui_3 e Leaky ReLU - Acurácia:

Estadística	Erro	Descrição	Estadística	Acurácia	Descrição		
0	count	50.000000	Número de repetições	0	count	50.000000	Número de repetições
1	mean	0.712535	Média dos erros	1	mean	0.777500	Média das acurácias
2	std	0.409587	Desvio padrão	2	std	0.055987	Desvio padrão
3	min	0.145772	Valor mínimo	3	min	0.687500	Valor mínimo
4	25%	0.471334	Primeiro quartil (25%)	4	25%	0.750000	Primeiro quartil (25%)
5	50%	0.610364	Mediana (50%)	5	50%	0.781250	Mediana (50%)
6	75%	0.815277	Terceiro quartil (75%)	6	75%	0.812500	Terceiro quartil (75%)
7	max	1.975802	Valor máximo	7	max	0.875000	Valor máximo



FONTE: A autora (2024).

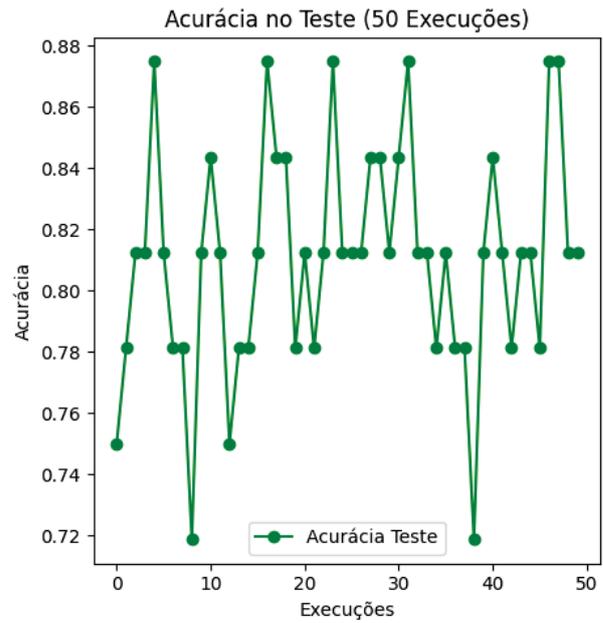
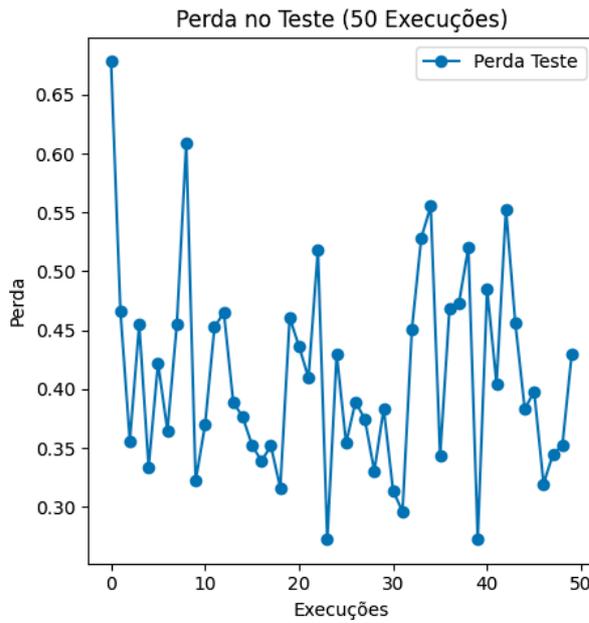
FIGURA 33 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_1, ARQUI_1, FUNÇÃO ELU E 100 ÉPOCAS

Arqui_1 - Elu - 100 Épocas - Erro:

Estatística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 0.411694	Média dos erros
2	std 0.085569	Desvio padrão
3	min 0.272426	Valor mínimo
4	25% 0.352089	Primeiro quartil (25%)
5	50% 0.393670	Mediana (50%)
6	75% 0.459566	Terceiro quartil (75%)
7	max 0.678296	Valor máximo

Arqui_1 - Elu - 100 Épocas - Acurácia:

Estatística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.810625	Média das acurácias
2	std 0.037035	Desvio padrão
3	min 0.718750	Valor mínimo
4	25% 0.781250	Primeiro quartil (25%)
5	50% 0.812500	Mediana (50%)
6	75% 0.835938	Terceiro quartil (75%)
7	max 0.875000	Valor máximo



FONTE: A autora (2024).

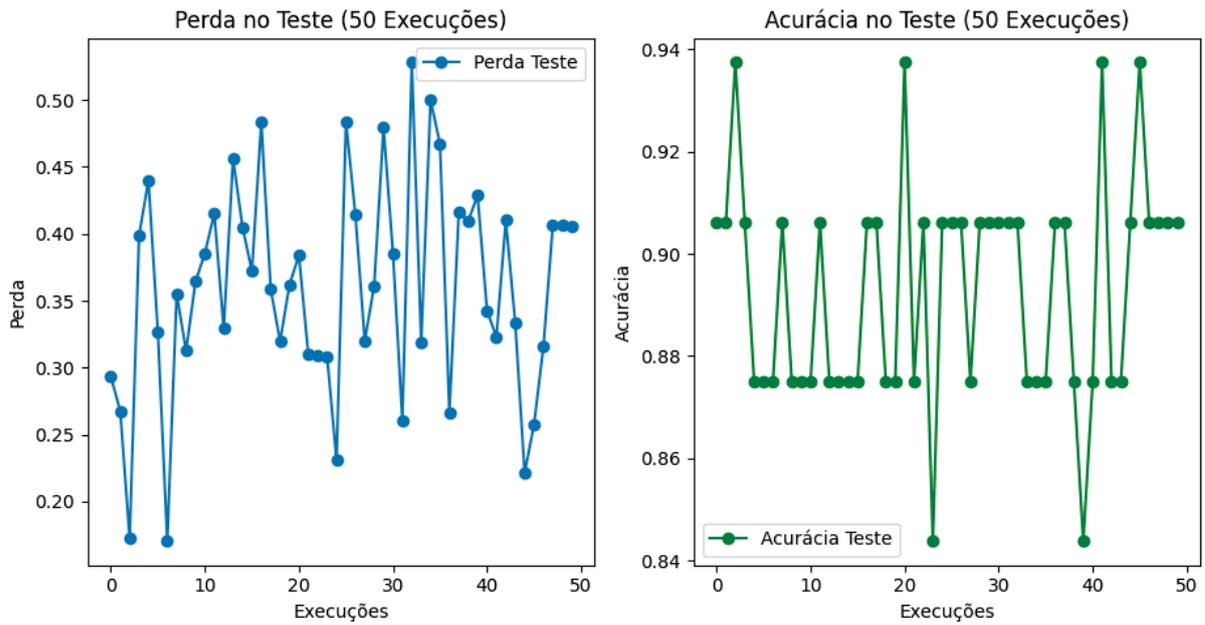
FIGURA 34 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_1, ARQUI_1, FUNÇÃO ELU E 500 ÉPOCAS

Arqui_1 - Elu - 500 Épocas - Erro:

Estatística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 0.359835	Média dos erros
2	std 0.080969	Desvio padrão
3	min 0.170340	Valor mínimo
4	25% 0.313387	Primeiro quartil (25%)
5	50% 0.361606	Mediana (50%)
6	75% 0.409968	Terceiro quartil (75%)
7	max 0.528238	Valor máximo

Arqui_1 - Elu - 500 Épocas - Acurácia:

Estatística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.893125	Média das acurácias
2	std 0.021952	Desvio padrão
3	min 0.843750	Valor mínimo
4	25% 0.875000	Primeiro quartil (25%)
5	50% 0.906250	Mediana (50%)
6	75% 0.906250	Terceiro quartil (75%)
7	max 0.937500	Valor máximo

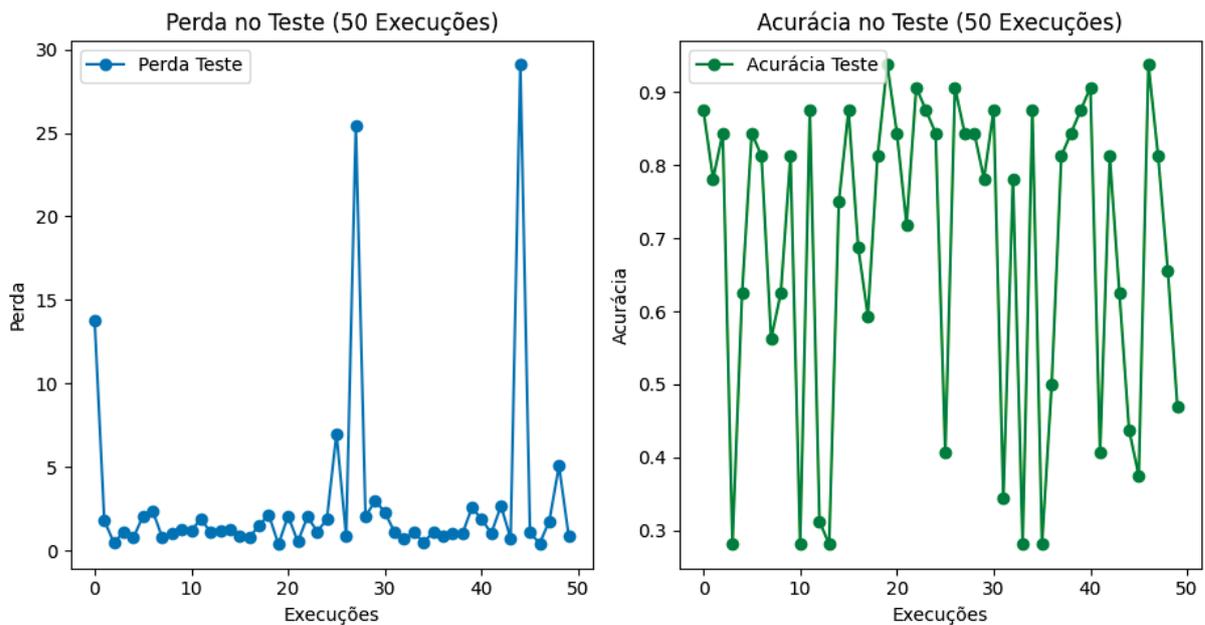


FONTE: A autora (2024).

FIGURA 35 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_1, ARQUI_1, FUNÇÃO ELU, 300 ÉPOCAS E TAXA DE APRENDIZAGEM 0,1

Arqui_1 - Elu - 300 Épocas - 0,1 Tx_Apren - Erro: Arqui_1 - Elu - 300 Épocas - 0,1 Tx_Apren - Acurácia:

Estadística	Erro	Descrição	Estadística	Acurácia	Descrição
0	count	50.000000 Número de repetições	0	count	50.000000 Número de repetições
1	mean	2.821566 Média dos erros	1	mean	0.686875 Média das acurácias
2	std	5.462026 Desvio padrão	2	std	0.218202 Desvio padrão
3	min	0.385767 Valor mínimo	3	min	0.281250 Valor mínimo
4	25%	0.882507 Primeiro quartil (25%)	4	25%	0.515625 Primeiro quartil (25%)
5	50%	1.184600 Mediana (50%)	5	50%	0.796875 Mediana (50%)
6	75%	2.067918 Terceiro quartil (75%)	6	75%	0.843750 Terceiro quartil (75%)
7	max	29.092634 Valor máximo	7	max	0.937500 Valor máximo



FONTE: A autora (2024).

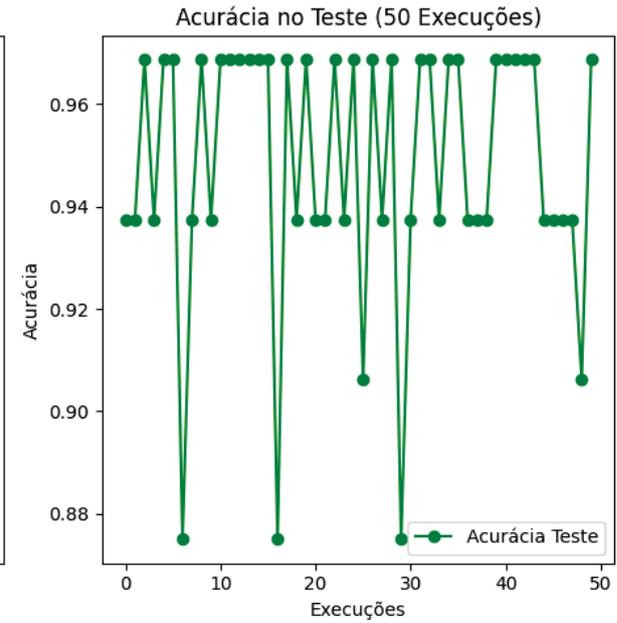
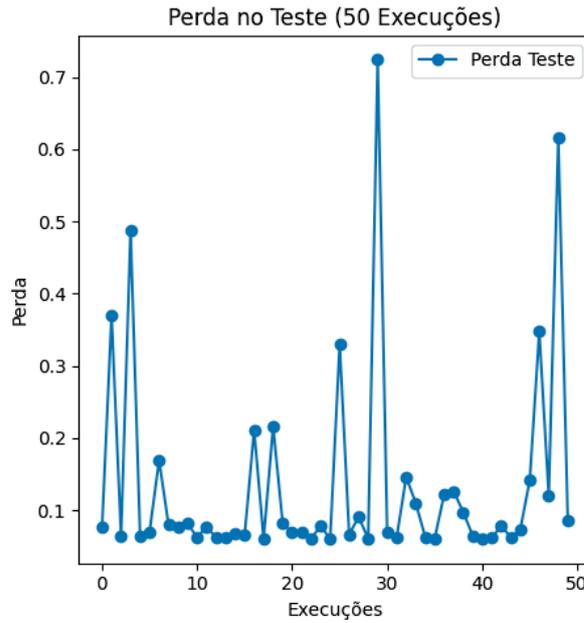
FIGURA 36 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_1, ARQUI_1, FUNÇÃO ELU, 300 ÉPOCAS E TAXA DE APRENDIZAGEM 0,01

Arqui_1 - Elu - 300 Épocas - 0,01 Tx_Apren - Erro:

Arqui_1 - Elu - 300 Épocas - 0,01 Tx_Apren - Acurácia:

Estadística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 0.133858	Média dos erros
2	std 0.143285	Desvio padrão
3	min 0.059991	Valor mínimo
4	25% 0.063722	Primeiro quartil (25%)
5	50% 0.076697	Mediana (50%)
6	75% 0.121875	Terceiro quartil (75%)
7	max 0.724233	Valor máximo

Estadística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.948750	Média das acurácias
2	std 0.025847	Desvio padrão
3	min 0.875000	Valor mínimo
4	25% 0.937500	Primeiro quartil (25%)
5	50% 0.968750	Mediana (50%)
6	75% 0.968750	Terceiro quartil (75%)
7	max 0.968750	Valor máximo



FONTE: A autora (2024).

SEGUNDA PARTE (RN_21, RN_22 E RN_23)

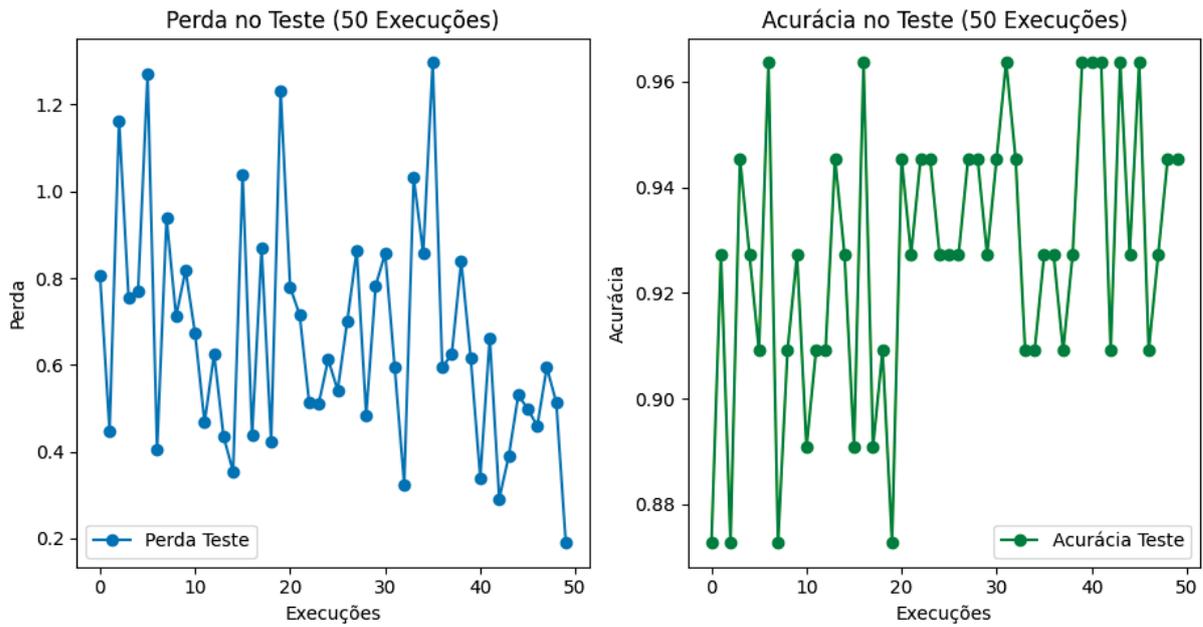
FIGURA 37 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_21, ARQUI_1, FUNÇÃO RELU

Arqui_1 - Relu - Erro:

Arqui_1 - Relu - Acurácia:

Estadística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 0.664922	Média dos erros
2	std 0.258353	Desvio padrão
3	min 0.189629	Valor mínimo
4	25% 0.471449	Primeiro quartil (25%)
5	50% 0.619445	Mediana (50%)
6	75% 0.815071	Terceiro quartil (75%)
7	max 1.297158	Valor máximo

Estadística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.926909	Média das acurácias
2	std 0.026101	Desvio padrão
3	min 0.872727	Valor mínimo
4	25% 0.909091	Primeiro quartil (25%)
5	50% 0.927273	Mediana (50%)
6	75% 0.945455	Terceiro quartil (75%)
7	max 0.963636	Valor máximo



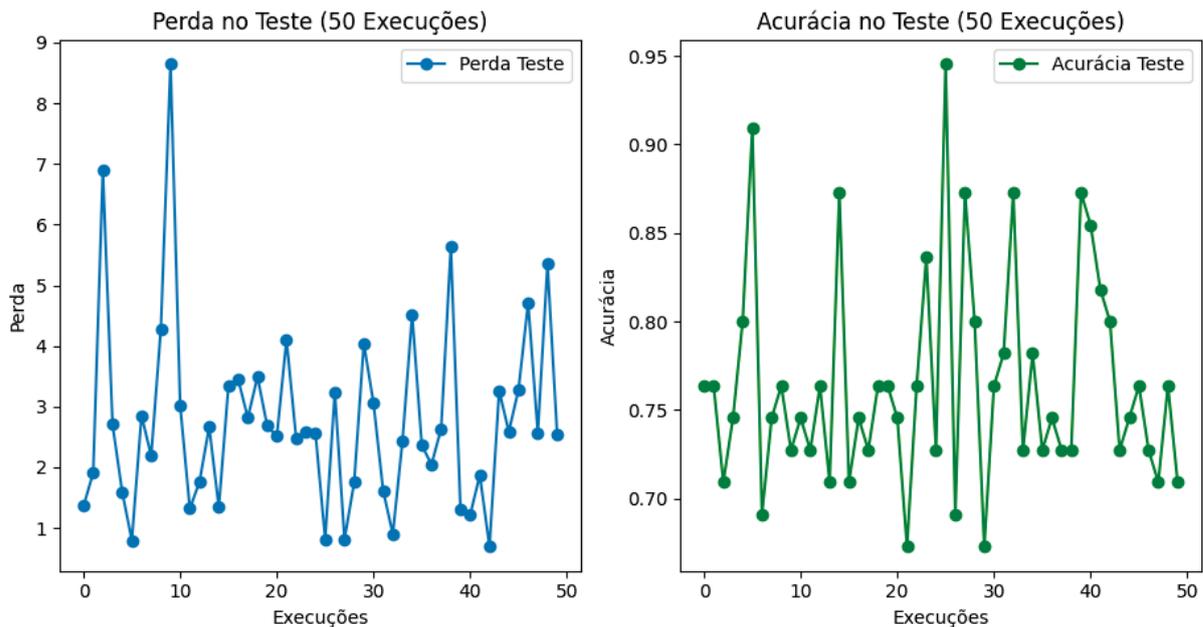
FONTE: A autora (2024).
 FIGURA 38 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_22, ARQUI_1, FUNÇÃO RELU

Arqui_1 - Relu - Erro:

Estadística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 2.771896	Média dos erros
2	std 1.558307	Desvio padrão
3	min 0.691326	Valor mínimo
4	25% 1.753147	Primeiro quartil (25%)
5	50% 2.578516	Mediana (50%)
6	75% 3.272914	Terceiro quartil (75%)
7	max 8.647799	Valor máximo

Arqui_1 - Relu - Acurácia:

Estadística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.764364	Média das acurácias
2	std 0.060688	Desvio padrão
3	min 0.672727	Valor mínimo
4	25% 0.727273	Primeiro quartil (25%)
5	50% 0.745455	Mediana (50%)
6	75% 0.781818	Terceiro quartil (75%)
7	max 0.945455	Valor máximo



FONTE: A autora (2024).

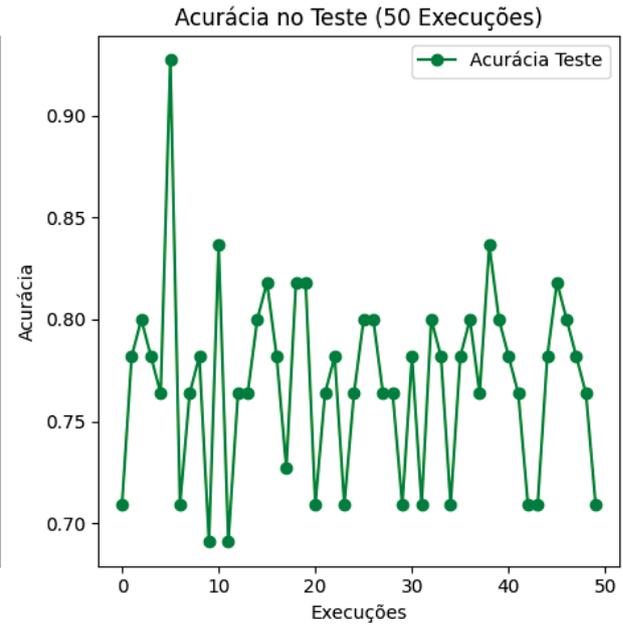
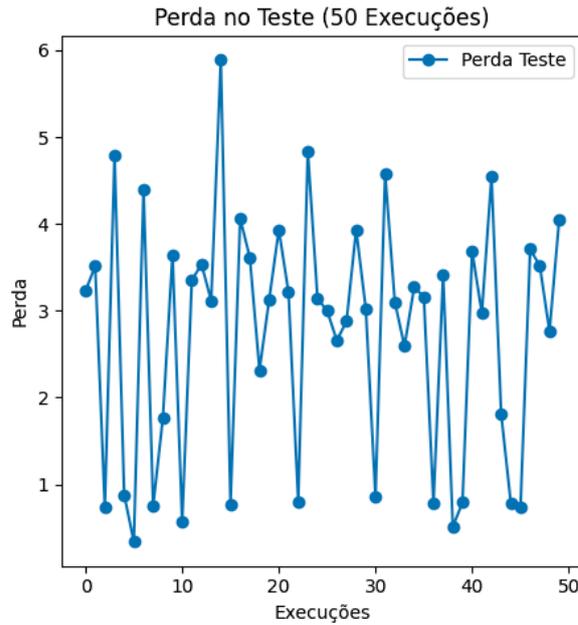
FIGURA 39 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_23, ARQUI_1, FUNÇÃO RELU

Arqui_1 - Relu - Erro:

Estatística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 2.749000	Média dos erros
2	std 1.410679	Desvio padrão
3	min 0.339092	Valor mínimo
4	25% 1.101551	Primeiro quartil (25%)
5	50% 3.122984	Mediana (50%)
6	75% 3.637076	Terceiro quartil (75%)
7	max 5.889533	Valor máximo

Arqui_1 - Relu - Acurácia:

Estatística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.769455	Média das acurácias
2	std 0.045944	Desvio padrão
3	min 0.690909	Valor mínimo
4	25% 0.736364	Primeiro quartil (25%)
5	50% 0.781818	Mediana (50%)
6	75% 0.800000	Terceiro quartil (75%)
7	max 0.927273	Valor máximo



FONTE: A autora (2024).

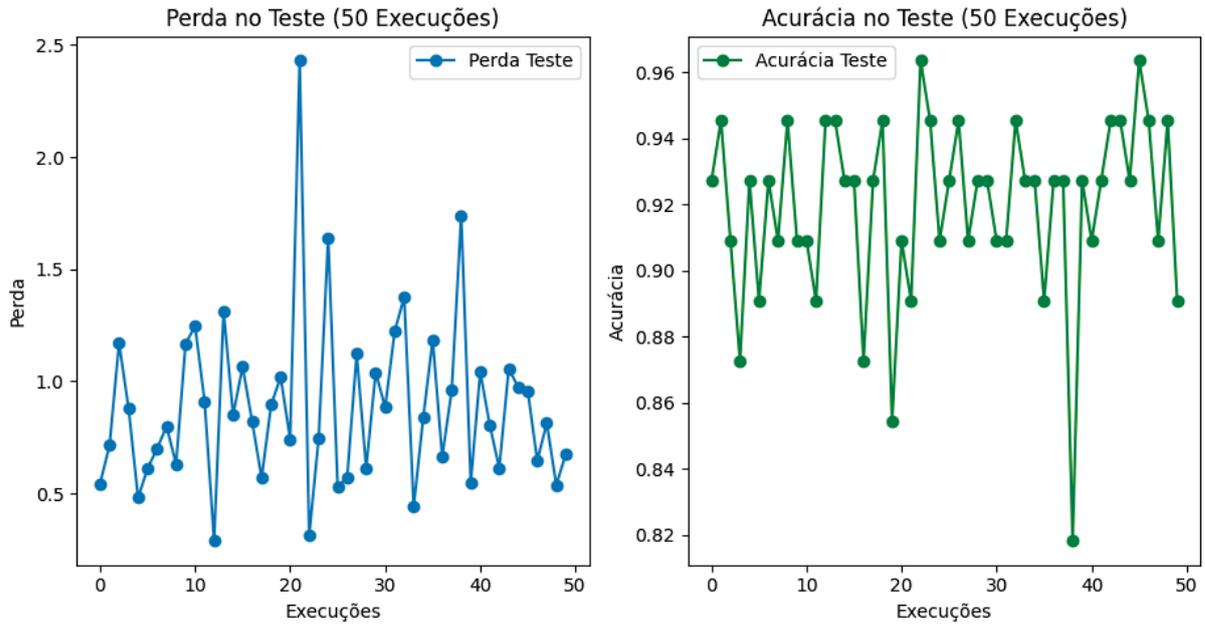
FIGURA 40 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_21, ARQUI_1, FUNÇÃO ELU

Arqui_1 - Elu - Erro:

Estatística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 0.888218	Média dos erros
2	std 0.380770	Desvio padrão
3	min 0.288410	Valor mínimo
4	25% 0.618566	Primeiro quartil (25%)
5	50% 0.829225	Mediana (50%)
6	75% 1.053046	Terceiro quartil (75%)
7	max 2.431495	Valor máximo

Arqui_1 - Elu - Acurácia:

Estatística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.919636	Média das acurácias
2	std 0.027510	Desvio padrão
3	min 0.818182	Valor mínimo
4	25% 0.909091	Primeiro quartil (25%)
5	50% 0.927273	Mediana (50%)
6	75% 0.945455	Terceiro quartil (75%)
7	max 0.963636	Valor máximo



FONTE: A autora (2024).

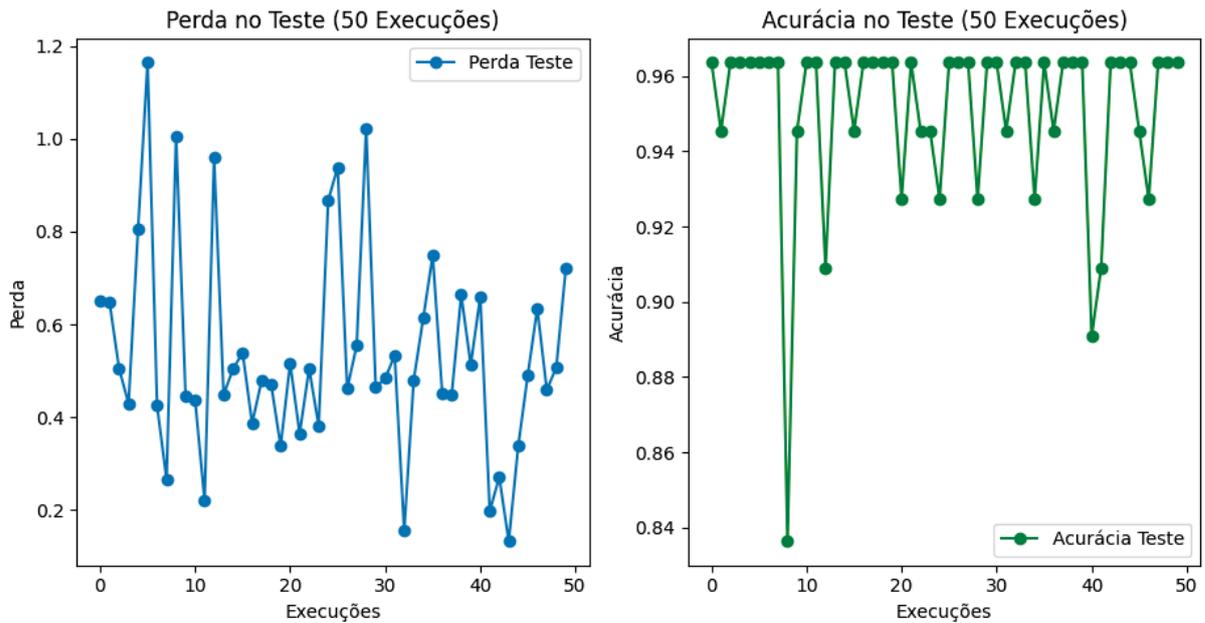
FIGURA 41 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_22, ARQUI_1, FUNÇÃO ELU

Arqui_1 - Elu - Erro:

Estatística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 0.534093	Média dos erros
2	std 0.223446	Desvio padrão
3	min 0.132642	Valor mínimo
4	25% 0.431345	Primeiro quartil (25%)
5	50% 0.487240	Mediana (50%)
6	75% 0.644450	Terceiro quartil (75%)
7	max 1.164406	Valor máximo

Arqui_1 - Elu - Acurácia:

Estatística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.950909	Média das acurácias
2	std 0.024157	Desvio padrão
3	min 0.836364	Valor mínimo
4	25% 0.945455	Primeiro quartil (25%)
5	50% 0.963636	Mediana (50%)
6	75% 0.963636	Terceiro quartil (75%)
7	max 0.963636	Valor máximo



FONTE: A autora (2024).

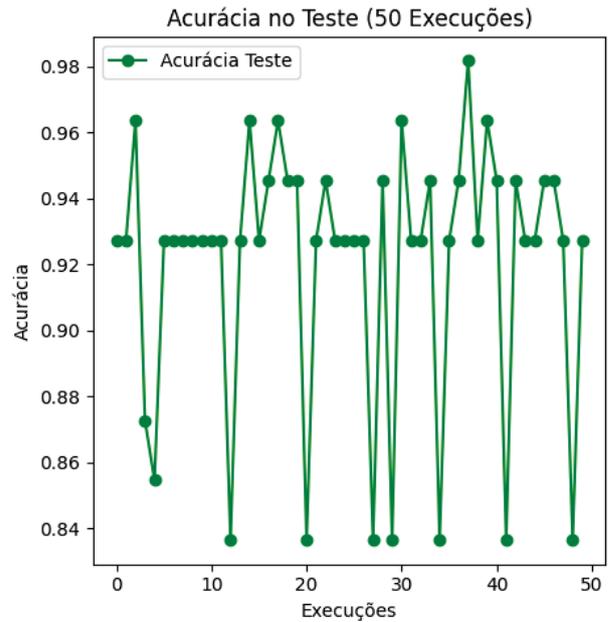
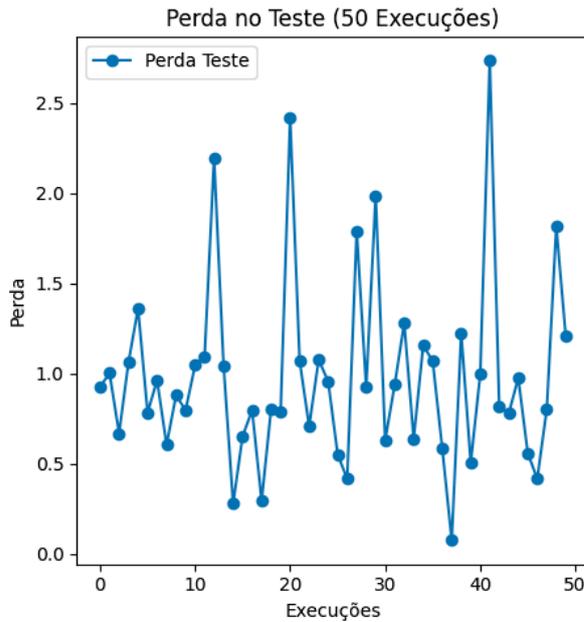
FIGURA 42 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_23, ARQUI_1, FUNÇÃO ELU

Arqui_1 - Elu - Erro:

Estatística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 0.982258	Média dos erros
2	std 0.526037	Desvio padrão
3	min 0.074156	Valor mínimo
4	25% 0.656237	Primeiro quartil (25%)
5	50% 0.924512	Mediana (50%)
6	75% 1.074293	Terceiro quartil (75%)
7	max 2.736848	Valor máximo

Arqui_1 - Elu - Acurácia:

Estatística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.920727	Média das acurácias
2	std 0.039692	Desvio padrão
3	min 0.836364	Valor mínimo
4	25% 0.927273	Primeiro quartil (25%)
5	50% 0.927273	Mediana (50%)
6	75% 0.945455	Terceiro quartil (75%)
7	max 0.981818	Valor máximo



FONTE: A autora (2024).

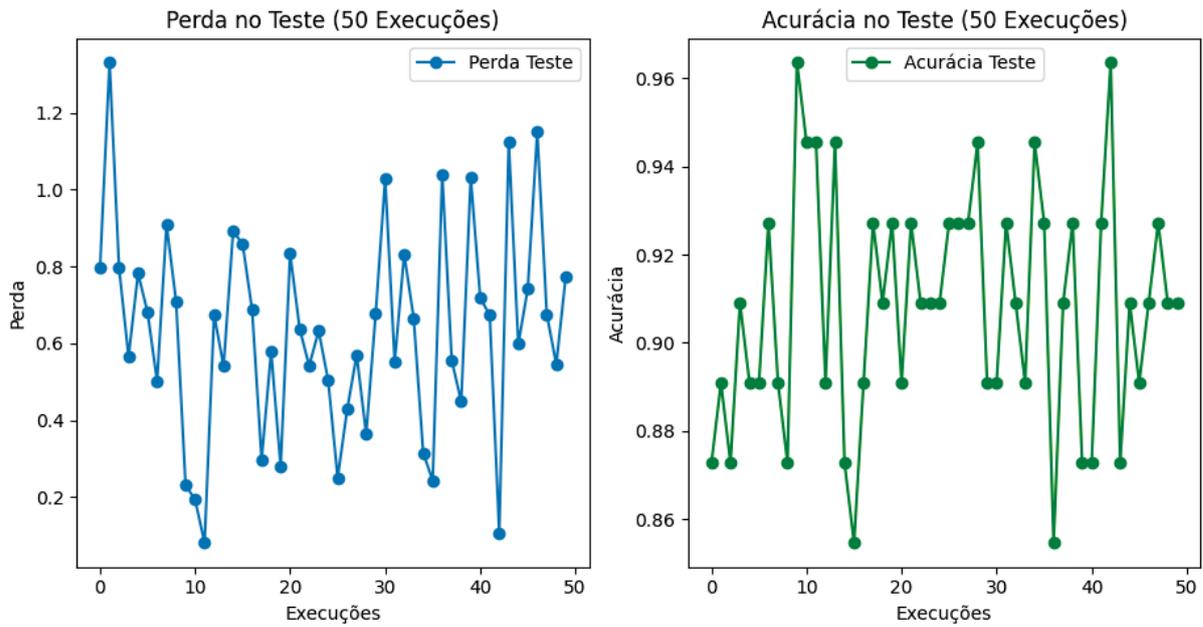
FIGURA 43 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_21, ARQUI_1, FUNÇÃO LEAKY RELU

Arqui_1 - Leaky ReLU - Erro:

Estatística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 0.632957	Média dos erros
2	std 0.274413	Desvio padrão
3	min 0.080997	Valor mínimo
4	25% 0.502230	Primeiro quartil (25%)
5	50% 0.651931	Mediana (50%)
6	75% 0.792542	Terceiro quartil (75%)
7	max 1.330889	Valor máximo

Arqui_1 - Leaky ReLU - Acurácia:

Estatística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.908000	Média das acurácias
2	std 0.026845	Desvio padrão
3	min 0.854545	Valor mínimo
4	25% 0.890909	Primeiro quartil (25%)
5	50% 0.909091	Mediana (50%)
6	75% 0.927273	Terceiro quartil (75%)
7	max 0.963636	Valor máximo



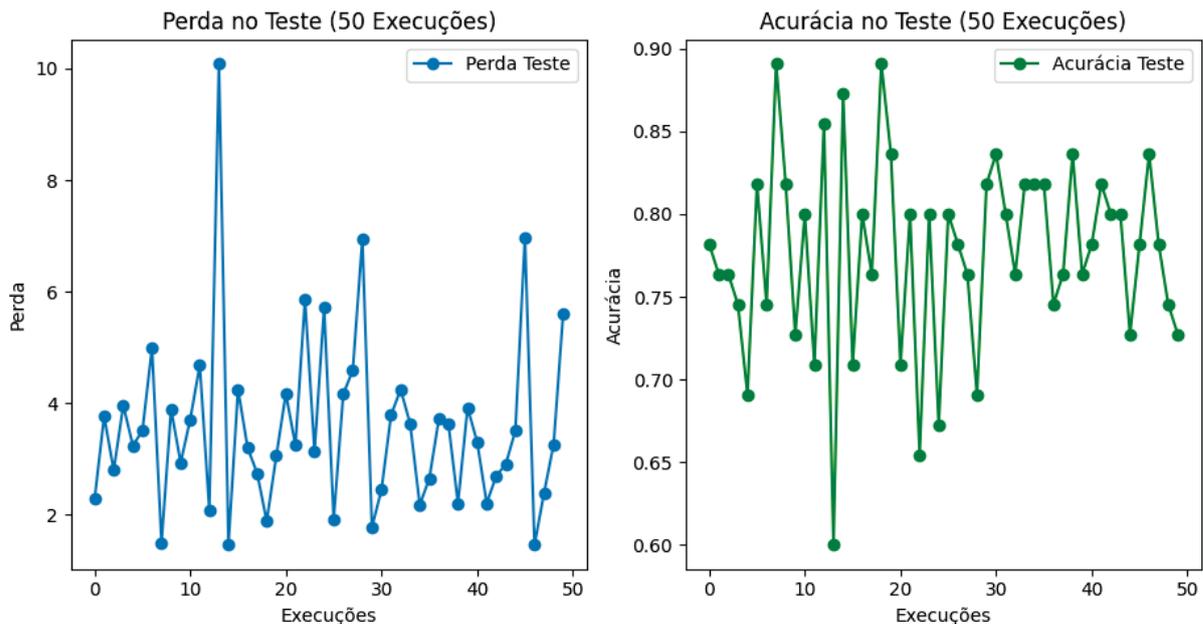
FONTE: A autora (2024).

FIGURA 44 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_22, ARQUI_1, FUNÇÃO LEAKY RELU

Arqui_1 - Leaky ReLU - Erro:

Arqui_1 - Leaky ReLU - Acurácia:

Estadística	Erro	Descrição	Estadística	Acurácia	Descrição
0	count 50.000000	Número de repetições	0	count 50.000000	Número de repetições
1	mean 3.567794	Média dos erros	1	mean 0.776727	Média das acurácias
2	std 1.595602	Desvio padrão	2	std 0.058892	Desvio padrão
3	min 1.461438	Valor mínimo	3	min 0.600000	Valor mínimo
4	25% 2.502296	Primeiro quartil (25%)	4	25% 0.745455	Primeiro quartil (25%)
5	50% 3.287072	Mediana (50%)	5	50% 0.781818	Mediana (50%)
6	75% 4.112300	Terceiro quartil (75%)	6	75% 0.818182	Terceiro quartil (75%)
7	max 10.087140	Valor máximo	7	max 0.890909	Valor máximo



FONTE: A autora (2024).

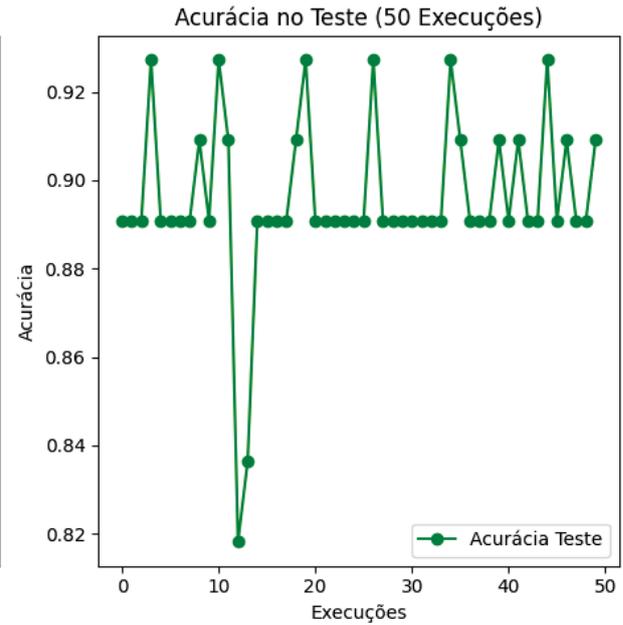
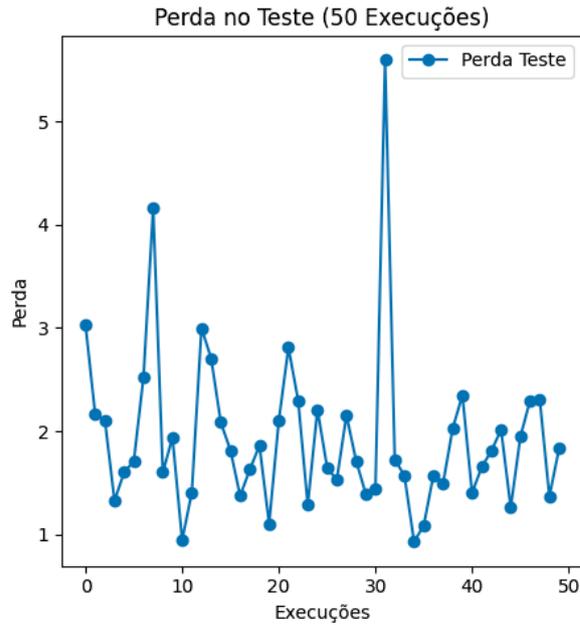
FIGURA 45 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_23, ARQUI_1, FUNÇÃO LEAKY RELU

Arqui_1 - Leaky ReLU - Erro:

Estatística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 1.938727	Média dos erros
2	std 0.794837	Desvio padrão
3	min 0.928656	Valor mínimo
4	25% 1.453971	Primeiro quartil (25%)
5	50% 1.767727	Mediana (50%)
6	75% 2.161669	Terceiro quartil (75%)
7	max 5.598072	Valor máximo

Arqui_1 - Leaky ReLU - Acurácia:

Estatística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.895636	Média das acurácias
2	std 0.019020	Desvio padrão
3	min 0.818182	Valor mínimo
4	25% 0.890909	Primeiro quartil (25%)
5	50% 0.890909	Mediana (50%)
6	75% 0.909091	Terceiro quartil (75%)
7	max 0.927273	Valor máximo



FONTE: A autora (2024).

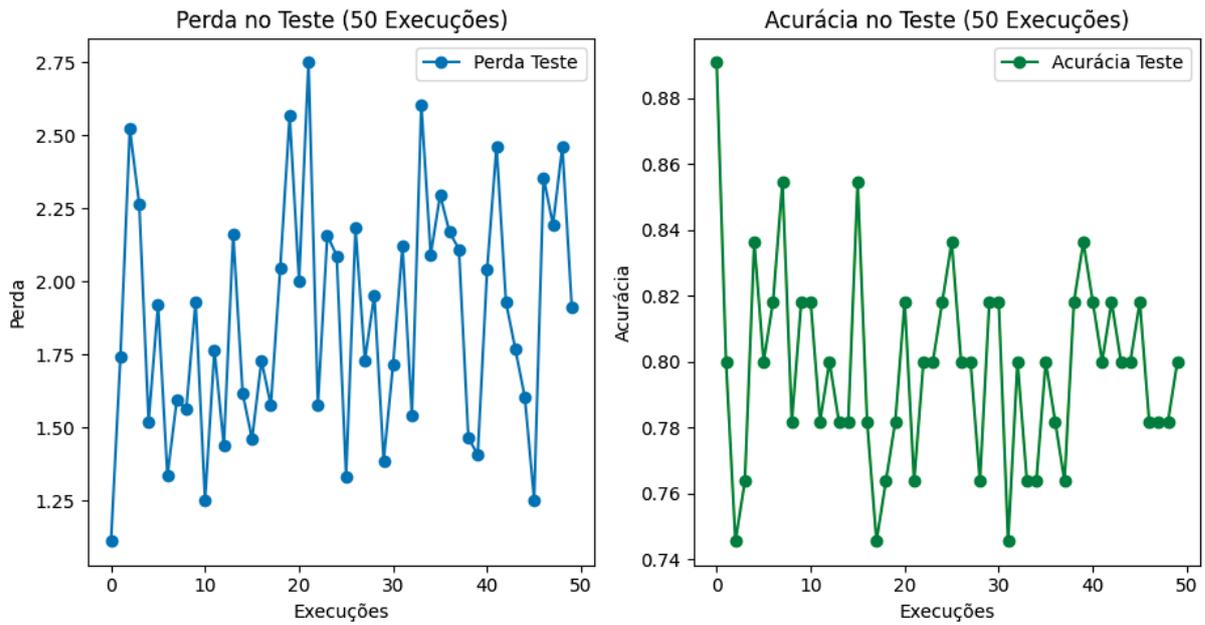
FIGURA 46 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_21, ARQUI_2, FUNÇÃO RELU

Arqui_2 - Relu - Erro:

Estatística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 1.876061	Média dos erros
2	std 0.402992	Desvio padrão
3	min 1.111469	Valor mínimo
4	25% 1.566505	Primeiro quartil (25%)
5	50% 1.916244	Mediana (50%)
6	75% 2.161438	Terceiro quartil (75%)
7	max 2.750342	Valor máximo

Arqui_2 - Relu - Acurácia:

Estatística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.798182	Média das acurácias
2	std 0.029672	Desvio padrão
3	min 0.745455	Valor mínimo
4	25% 0.781818	Primeiro quartil (25%)
5	50% 0.800000	Mediana (50%)
6	75% 0.818182	Terceiro quartil (75%)
7	max 0.890909	Valor máximo



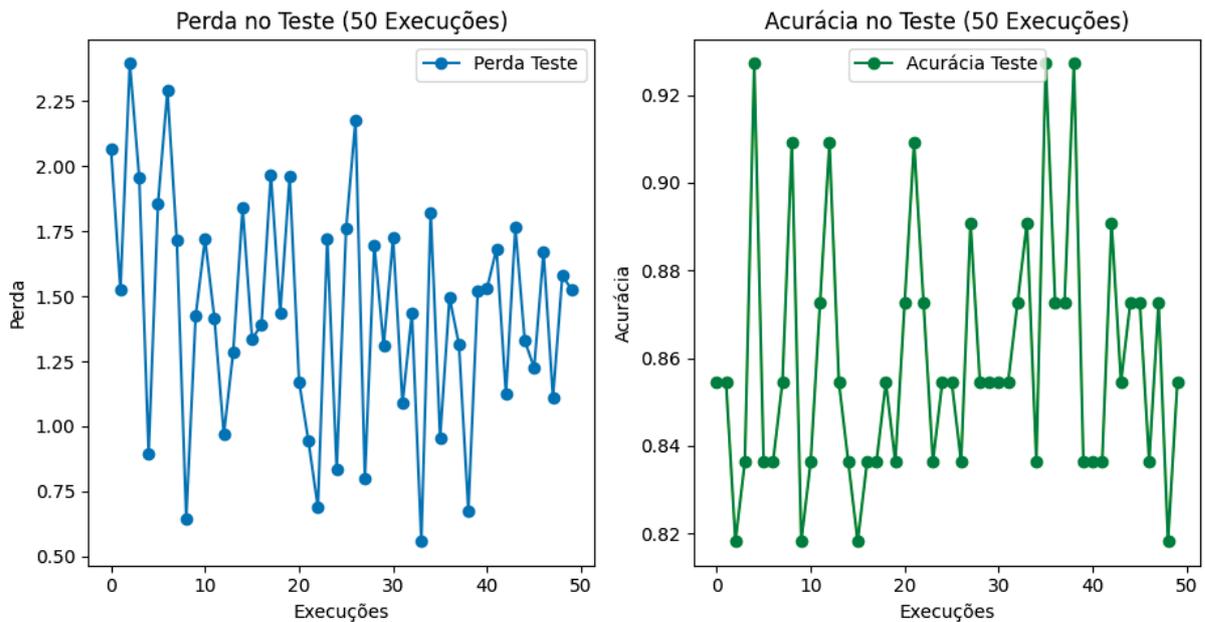
FONTE: A autora (2024).

FIGURA 47 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_22, ARQUI_2, FUNÇÃO RELU

Arqui_2 - Relu - Erro:

Arqui_2 - Relu - Acurácia:

Estadística	Erro	Descrição	Estadística	Acurácia	Descrição
0	count 50.000000	Número de repetições	0	count 50.000000	Número de repetições
1	mean 1.446785	Média dos erros	1	mean 0.859273	Média das acurácias
2	std 0.440167	Desvio padrão	2	std 0.028879	Desvio padrão
3	min 0.557193	Valor mínimo	3	min 0.818182	Valor mínimo
4	25% 1.135888	Primeiro quartil (25%)	4	25% 0.836364	Primeiro quartil (25%)
5	50% 1.466766	Mediana (50%)	5	50% 0.854545	Mediana (50%)
6	75% 1.724518	Terceiro quartil (75%)	6	75% 0.872727	Terceiro quartil (75%)
7	max 2.396562	Valor máximo	7	max 0.927273	Valor máximo



FONTE: A autora (2024).

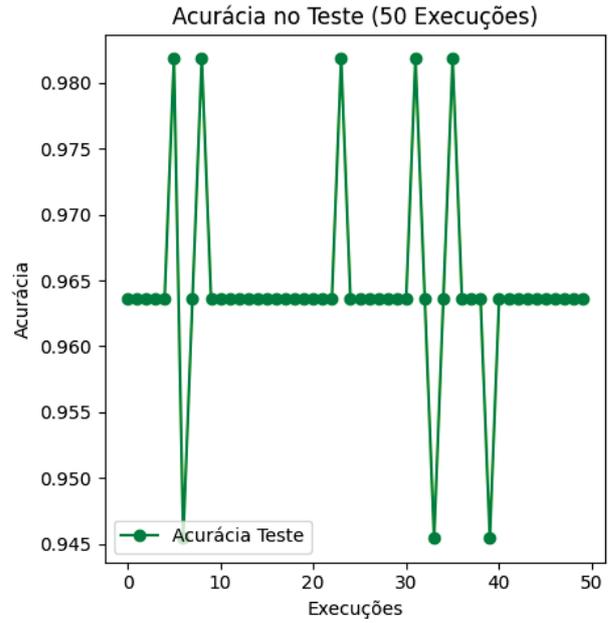
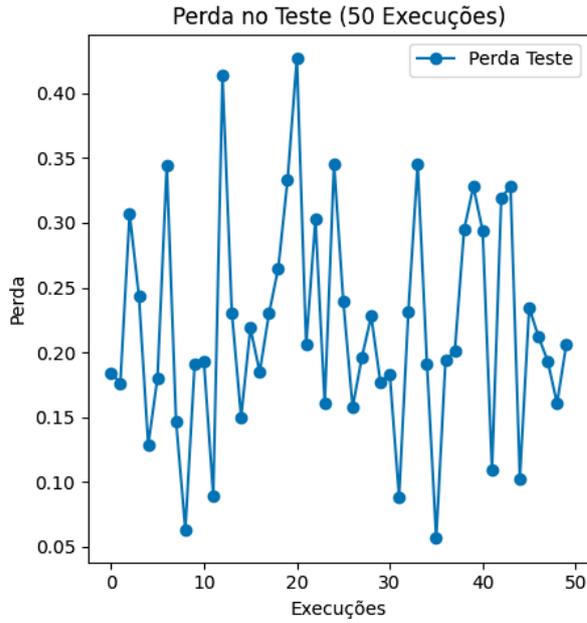
FIGURA 48 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_23, ARQUI_2, FUNÇÃO RELU

Arqui_2 - Relu - Erro:

Estadística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 0.219764	Média dos erros
2	std 0.085481	Desvio padrão
3	min 0.056581	Valor mínimo
4	25% 0.176390	Primeiro quartil (25%)
5	50% 0.203476	Mediana (50%)
6	75% 0.286530	Terceiro quartil (75%)
7	max 0.426877	Valor máximo

Arqui_2 - Relu - Acurácia:

Estadística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.964364	Média das acurácias
2	std 0.007310	Desvio padrão
3	min 0.945455	Valor mínimo
4	25% 0.963636	Primeiro quartil (25%)
5	50% 0.963636	Mediana (50%)
6	75% 0.963636	Terceiro quartil (75%)
7	max 0.981818	Valor máximo



FONTE: A autora (2024).

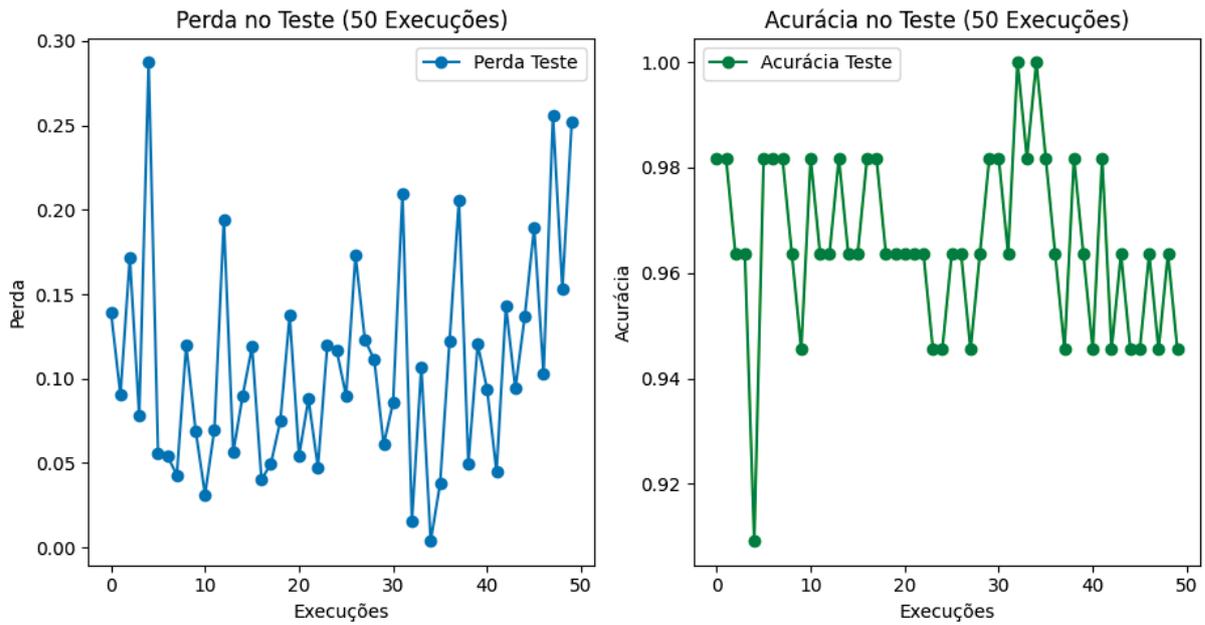
FIGURA 49 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_21, ARQUI_2, FUNÇÃO ELU

Arqui_2 - Elu - Erro:

Estadística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 0.107585	Média dos erros
2	std 0.063595	Desvio padrão
3	min 0.003707	Valor mínimo
4	25% 0.056190	Primeiro quartil (25%)
5	50% 0.093844	Mediana (50%)
6	75% 0.137297	Terceiro quartil (75%)
7	max 0.287473	Valor máximo

Arqui_2 - Elu - Acurácia:

Estadística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.965455	Média das acurácias
2	std 0.016933	Desvio padrão
3	min 0.909091	Valor mínimo
4	25% 0.963636	Primeiro quartil (25%)
5	50% 0.963636	Mediana (50%)
6	75% 0.981818	Terceiro quartil (75%)
7	max 1.000000	Valor máximo

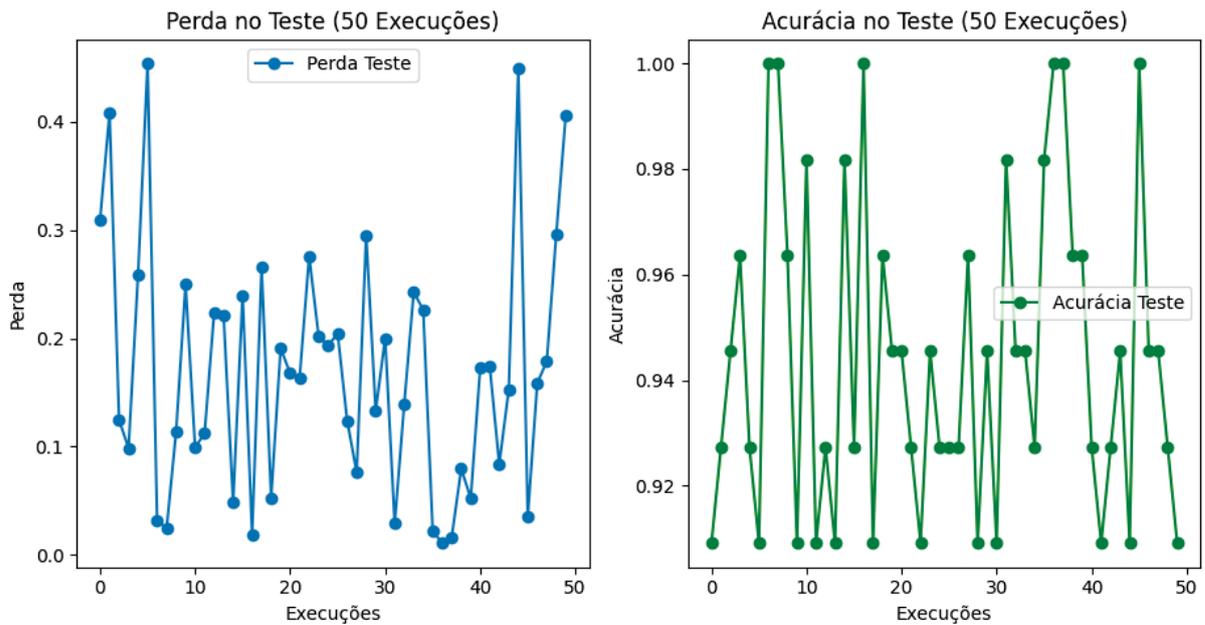


FONTE: A autora (2024).

FIGURA 50 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_22, ARQUI_2, FUNÇÃO ELU

Arqui_2 - Elu - Acurácia:

Estadística	Erro	Descrição	Estadística	Acurácia	Descrição		
0	count	50.000000	Número de repetições	0	count	50.000000	Número de repetições
1	mean	0.170112	Média dos erros	1	mean	0.944000	Média das acurácias
2	std	0.114469	Desvio padrão	2	std	0.030255	Desvio padrão
3	min	0.010752	Valor mínimo	3	min	0.909091	Valor mínimo
4	25%	0.080642	Primeiro quartil (25%)	4	25%	0.927273	Primeiro quartil (25%)
5	50%	0.165673	Mediana (50%)	5	50%	0.945455	Mediana (50%)
6	75%	0.236525	Terceiro quartil (75%)	6	75%	0.963636	Terceiro quartil (75%)
7	max	0.453922	Valor máximo	7	max	1.000000	Valor máximo



FONTE: A autora (2024).

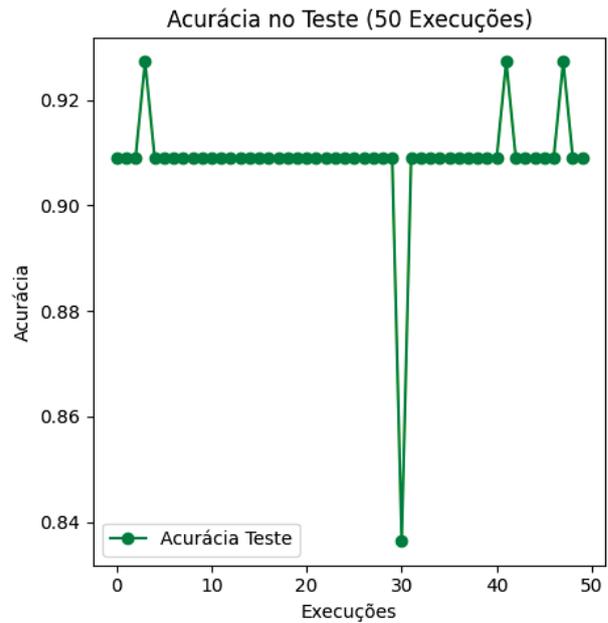
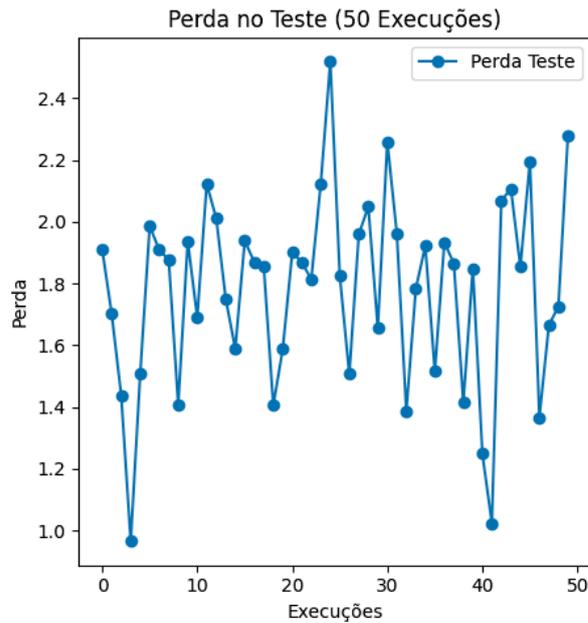
FIGURA 51 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_23, ARQUI_2, FUNÇÃO ELU

Arqui_2 - Elu - Erro:

Estatística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 1.782096	Média dos erros
2	std 0.311955	Desvio padrão
3	min 0.964796	Valor mínimo
4	25% 1.588275	Primeiro quartil (25%)
5	50% 1.854327	Mediana (50%)
6	75% 1.954493	Terceiro quartil (75%)
7	max 2.519782	Valor máximo

Arqui_2 - Elu - Acurácia:

Estatística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.908727	Média das acurácias
2	std 0.011316	Desvio padrão
3	min 0.836364	Valor mínimo
4	25% 0.909091	Primeiro quartil (25%)
5	50% 0.909091	Mediana (50%)
6	75% 0.909091	Terceiro quartil (75%)
7	max 0.927273	Valor máximo



FONTE: A autora (2024).

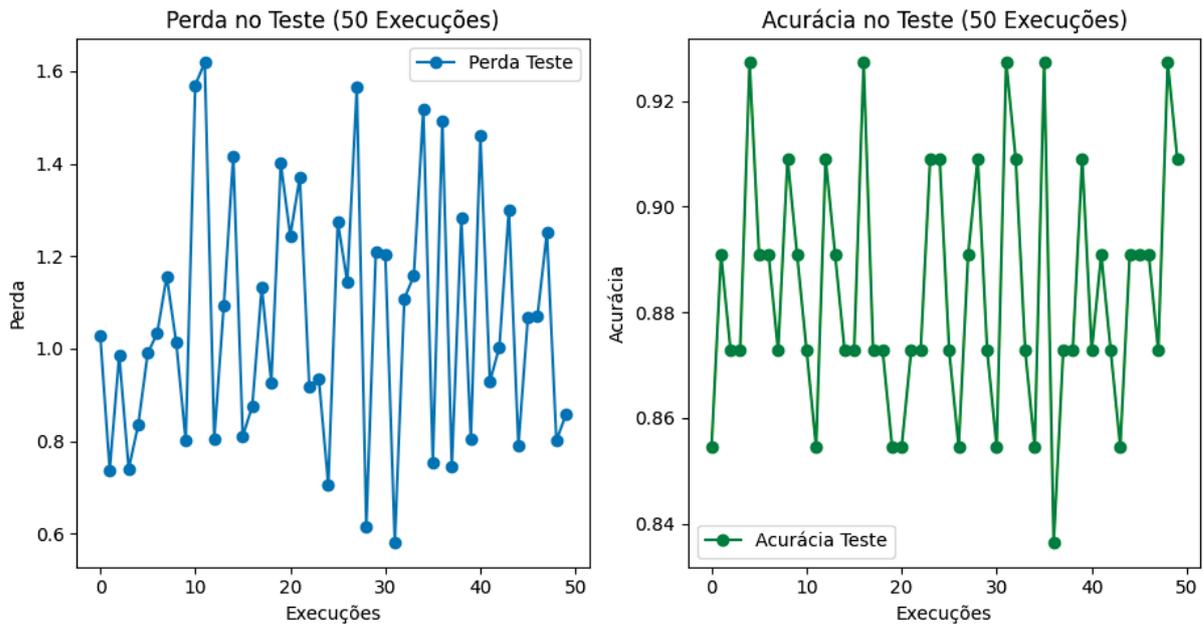
FIGURA 52 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_21, ARQUI_2, FUNÇÃO LEAKY RELU

Arqui_2 - Leaky ReLU - Erro:

Estatística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 1.062636	Média dos erros
2	std 0.270569	Desvio padrão
3	min 0.580144	Valor mínimo
4	25% 0.816932	Primeiro quartil (25%)
5	50% 1.031269	Mediana (50%)
6	75% 1.249279	Terceiro quartil (75%)
7	max 1.619000	Valor máximo

Arqui_2 - Leaky ReLU - Acurácia:

Estatística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.884000	Média das acurácias
2	std 0.023200	Desvio padrão
3	min 0.836364	Valor mínimo
4	25% 0.872727	Primeiro quartil (25%)
5	50% 0.872727	Mediana (50%)
6	75% 0.904545	Terceiro quartil (75%)
7	max 0.927273	Valor máximo



FONTE: A autora (2024).

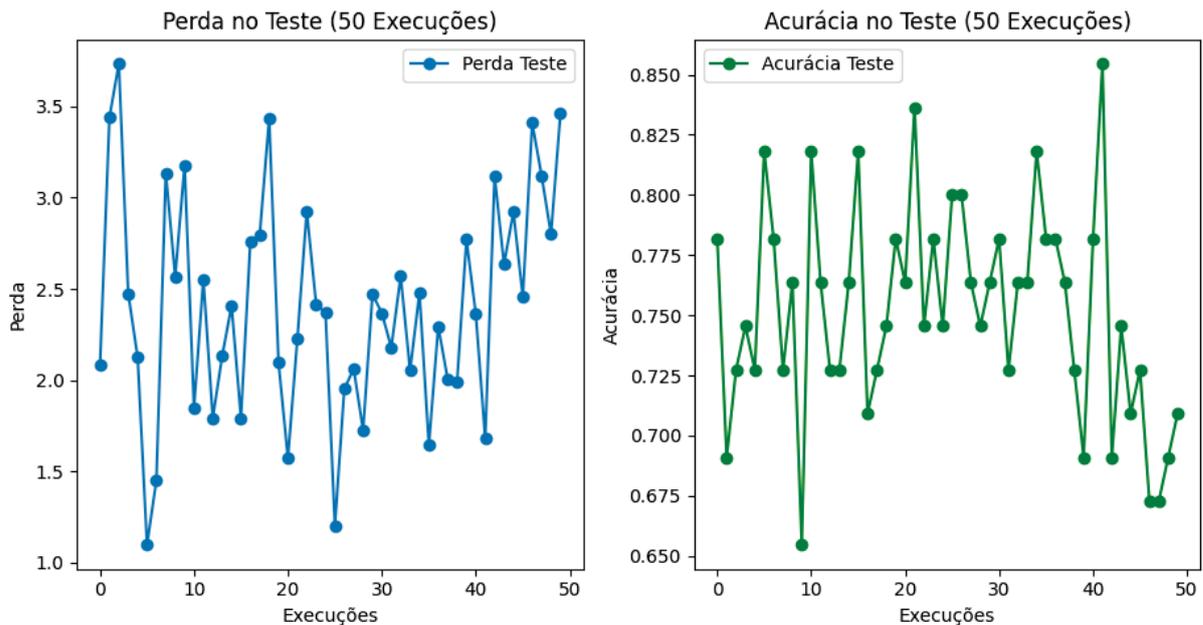
FIGURA 53 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_22, ARQUI_2, FUNÇÃO LEAKY RELU

Arqui_2 - Leaky ReLU - Erro:

Arqui_2 - Leaky ReLU - Acurácia:

Estadística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 2.402782	Média dos erros
2	std 0.606636	Desvio padrão
3	min 1.097527	Valor mínimo
4	25% 2.017801	Primeiro quartil (25%)
5	50% 2.388435	Mediana (50%)
6	75% 2.790913	Terceiro quartil (75%)
7	max 3.734112	Valor máximo

Estadística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.752000	Média das acurácias
2	std 0.044348	Desvio padrão
3	min 0.654545	Valor mínimo
4	25% 0.727273	Primeiro quartil (25%)
5	50% 0.754545	Mediana (50%)
6	75% 0.781818	Terceiro quartil (75%)
7	max 0.854545	Valor máximo



FONTE: A autora (2024).

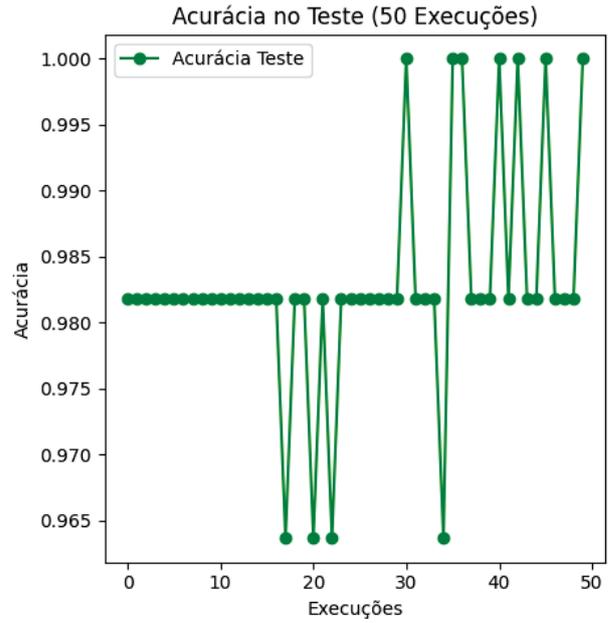
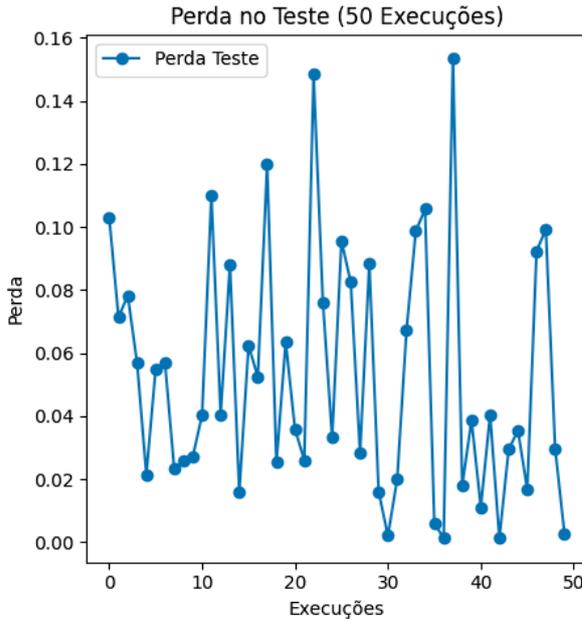
FIGURA 54 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_23, ARQUI_2, FUNÇÃO LEAKY RELU

Arqui_2 - Leaky ReLU - Erro:

Estatística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 0.052762	Média dos erros
2	std 0.038864	Desvio padrão
3	min 0.001282	Valor mínimo
4	25% 0.023749	Primeiro quartil (25%)
5	50% 0.040376	Mediana (50%)
6	75% 0.081397	Terceiro quartil (75%)
7	max 0.153439	Valor máximo

Arqui_2 - Leaky ReLU - Acurácia:

Estatística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.982909	Média das acurácias
2	std 0.008544	Desvio padrão
3	min 0.963636	Valor mínimo
4	25% 0.981818	Primeiro quartil (25%)
5	50% 0.981818	Mediana (50%)
6	75% 0.981818	Terceiro quartil (75%)
7	max 1.000000	Valor máximo



FONTE: A autora (2024).

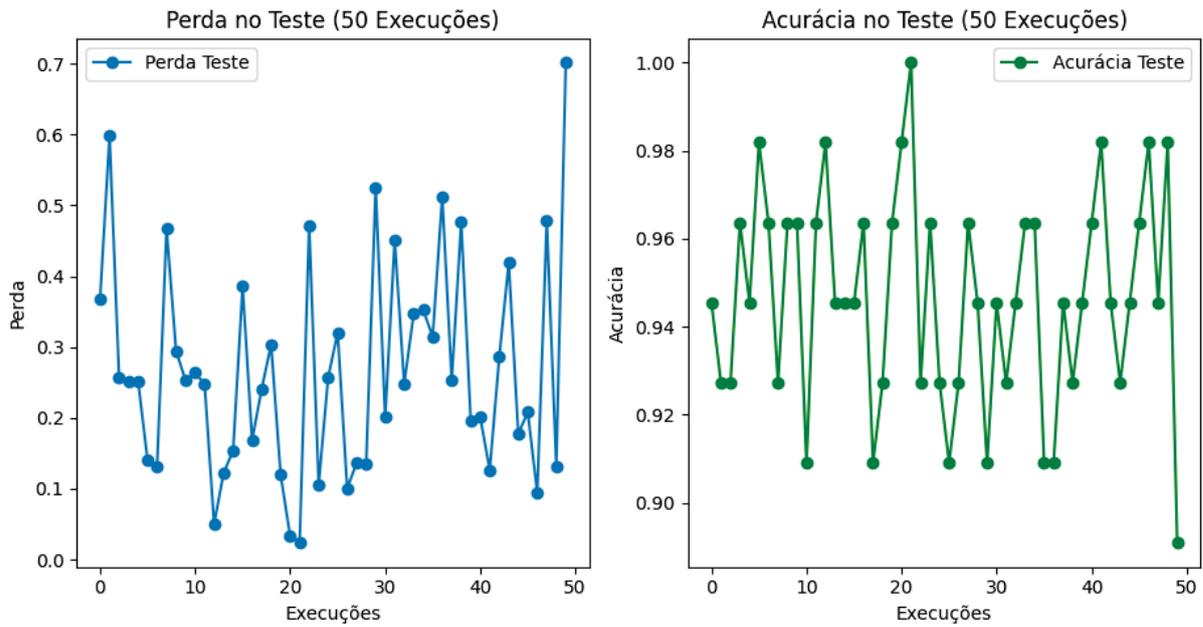
FIGURA 55 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_21, ARQUI_3, FUNÇÃO RELU

Arqui_3 - Relu - Erro:

Estatística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 0.266968	Média dos erros
2	std 0.152723	Desvio padrão
3	min 0.023404	Valor mínimo
4	25% 0.137534	Primeiro quartil (25%)
5	50% 0.252091	Mediana (50%)
6	75% 0.350823	Terceiro quartil (75%)
7	max 0.701741	Valor máximo

Arqui_3 - Relu - Acurácia:

Estatística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.946545	Média das acurácias
2	std 0.024479	Desvio padrão
3	min 0.890909	Valor mínimo
4	25% 0.927273	Primeiro quartil (25%)
5	50% 0.945455	Mediana (50%)
6	75% 0.963636	Terceiro quartil (75%)
7	max 1.000000	Valor máximo



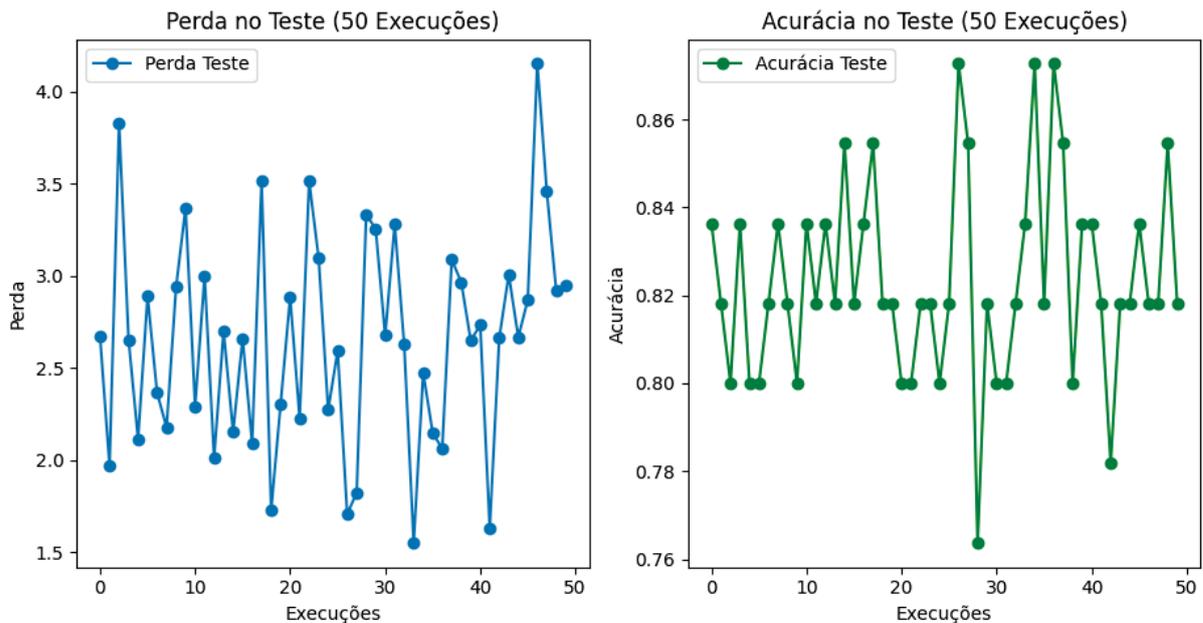
FONTE: A autora (2024).

FIGURA 56 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_22, ARQUI_3, FUNÇÃO RELU

Arqui_3 - Relu - Erro:

Arqui_3 - Relu - Acurácia:

Estadística	Erro	Descrição	Estadística	Acurácia	Descrição		
0	count	50.000000	Número de repetições	0	count	50.000000	Número de repetições
1	mean	2.654829	Média dos erros	1	mean	0.823273	Média das acurácias
2	std	0.582440	Desvio padrão	2	std	0.022656	Desvio padrão
3	min	1.549036	Valor mínimo	3	min	0.763636	Valor mínimo
4	25%	2.189718	Primeiro quartil (25%)	4	25%	0.818182	Primeiro quartil (25%)
5	50%	2.665733	Mediana (50%)	5	50%	0.818182	Mediana (50%)
6	75%	2.991872	Terceiro quartil (75%)	6	75%	0.836364	Terceiro quartil (75%)
7	max	4.154655	Valor máximo	7	max	0.872727	Valor máximo



FONTE: A autora (2024).

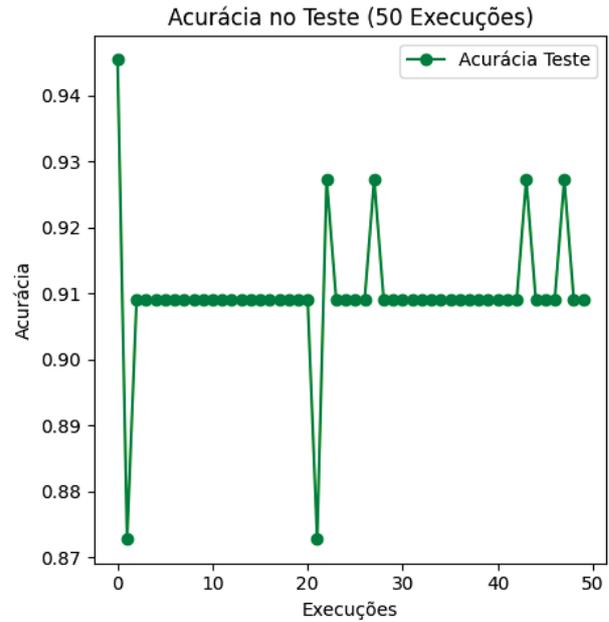
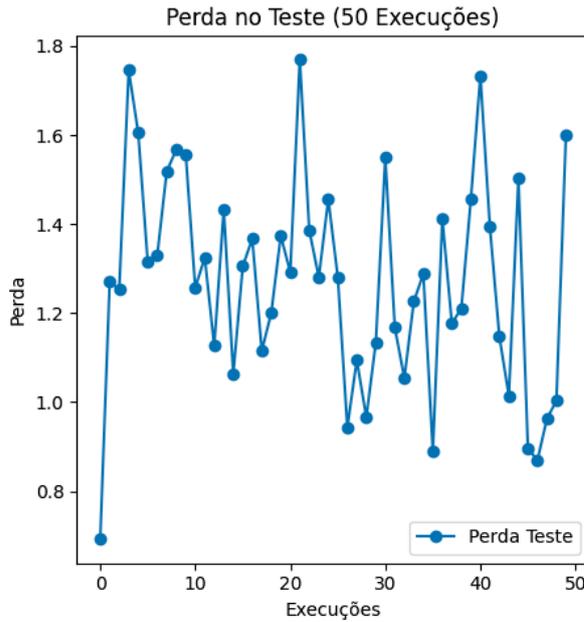
FIGURA 57 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_23, ARQUI_3, FUNÇÃO RELU

Arqui_3 - Relu - Erro:

Estatística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 1.271576	Média dos erros
2	std 0.242780	Desvio padrão
3	min 0.692101	Valor mínimo
4	25% 1.118018	Primeiro quartil (25%)
5	50% 1.280628	Mediana (50%)
6	75% 1.427447	Terceiro quartil (75%)
7	max 1.769952	Valor máximo

Arqui_3 - Relu - Acurácia:

Estatística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.909818	Média das acurácias
2	std 0.010364	Desvio padrão
3	min 0.872727	Valor mínimo
4	25% 0.909091	Primeiro quartil (25%)
5	50% 0.909091	Mediana (50%)
6	75% 0.909091	Terceiro quartil (75%)
7	max 0.945455	Valor máximo



FONTE: A autora (2024).

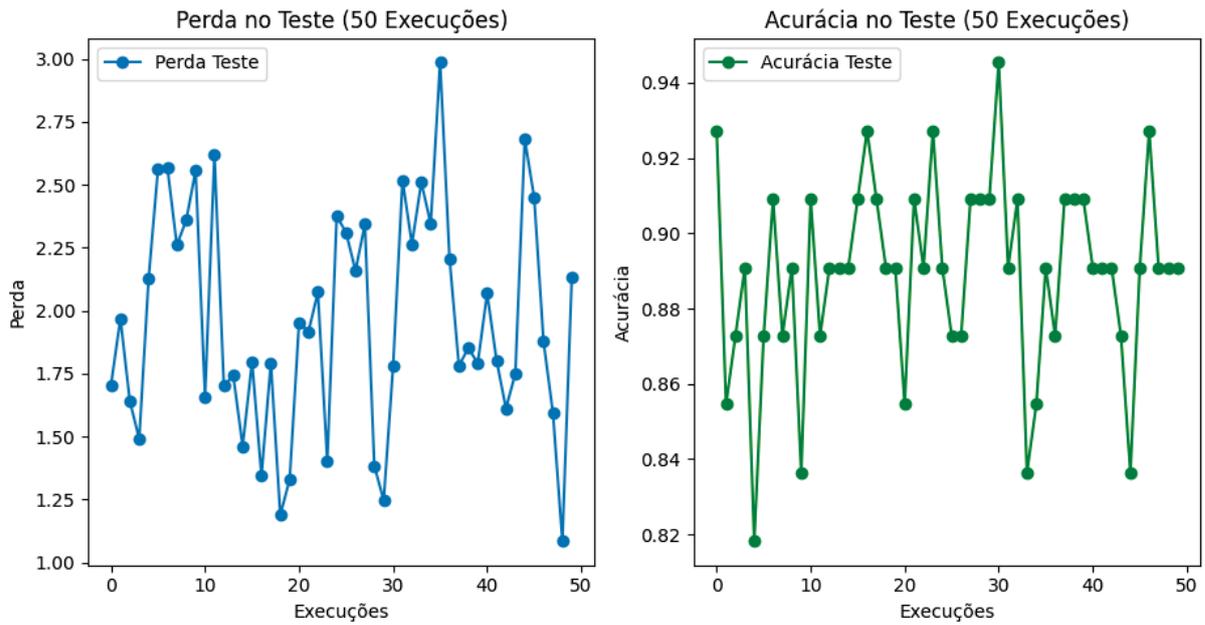
FIGURA 58 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_21, ARQUI_3, FUNÇÃO ELU

Arqui_3 - Elu - Erro:

Estatística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 1.962238	Média dos erros
2	std 0.445004	Desvio padrão
3	min 1.083736	Valor mínimo
4	25% 1.668924	Primeiro quartil (25%)
5	50% 1.896204	Mediana (50%)
6	75% 2.334708	Terceiro quartil (75%)
7	max 2.987042	Valor máximo

Arqui_3 - Elu - Acurácia:

Estatística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.889455	Média das acurácias
2	std 0.025932	Desvio padrão
3	min 0.818182	Valor mínimo
4	25% 0.872727	Primeiro quartil (25%)
5	50% 0.890909	Mediana (50%)
6	75% 0.909091	Terceiro quartil (75%)
7	max 0.945455	Valor máximo



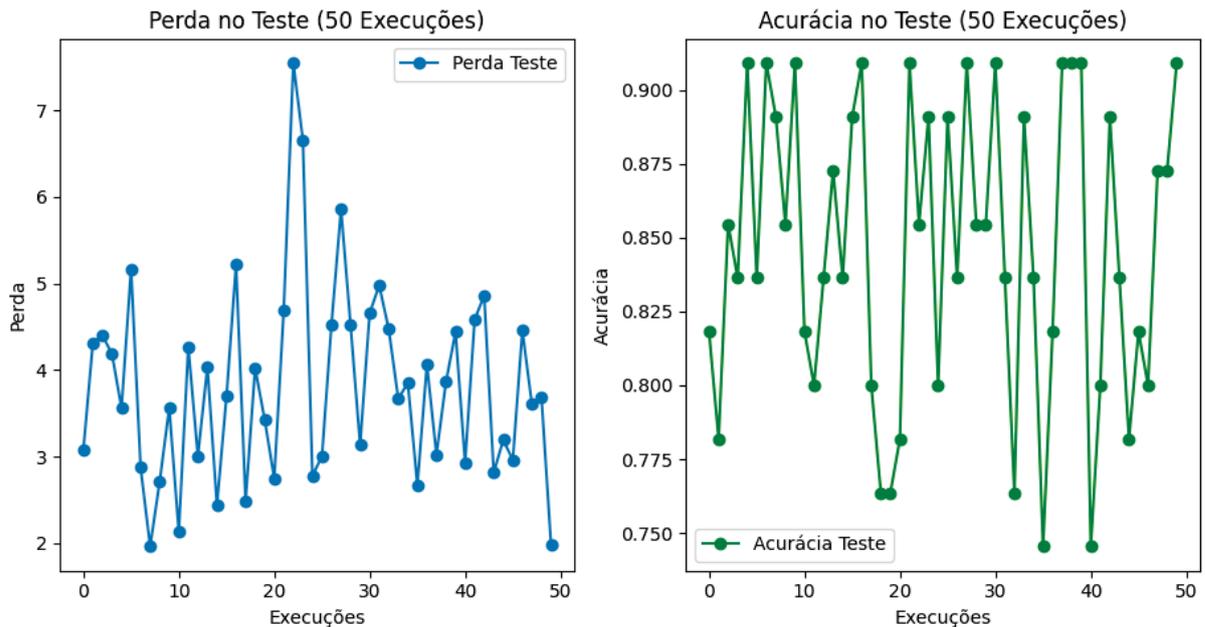
FONTE: A autora (2024).

FIGURA 59 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_22, ARQUI_3, FUNÇÃO ELU

Arqui_3 - Elu - Erro:

Arqui_3 - Elu - Acurácia:

Estadística	Erro	Descrição	Estadística	Acurácia	Descrição		
0	count	50.000000	Número de repetições	0	count	50.000000	Número de repetições
1	mean	3.816258	Média dos erros	1	mean	0.846545	Média das acurácias
2	std	1.133785	Desvio padrão	2	std	0.050654	Desvio padrão
3	min	1.961763	Valor mínimo	3	min	0.745455	Valor mínimo
4	25%	2.971497	Primeiro quartil (25%)	4	25%	0.804545	Primeiro quartil (25%)
5	50%	3.694155	Mediana (50%)	5	50%	0.845455	Mediana (50%)
6	75%	4.468938	Terceiro quartil (75%)	6	75%	0.890909	Terceiro quartil (75%)
7	max	7.548146	Valor máximo	7	max	0.909091	Valor máximo



FONTE: A autora (2024).

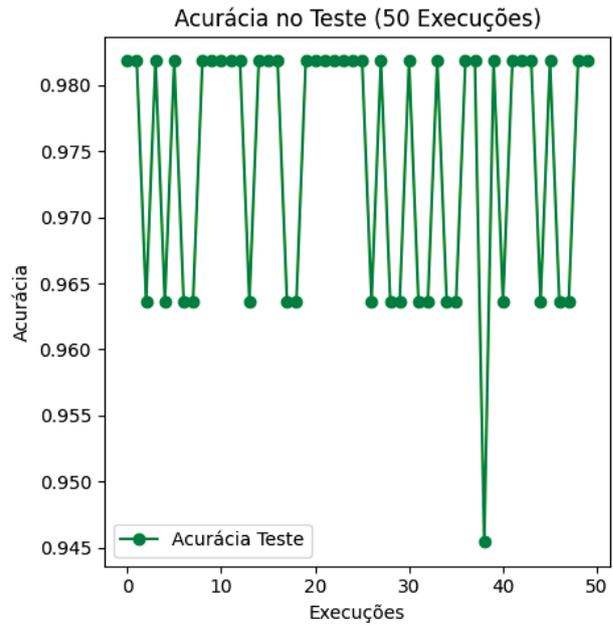
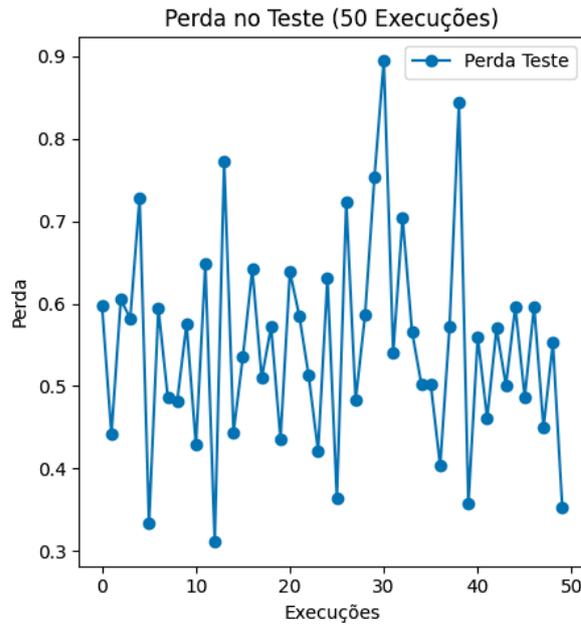
FIGURA 60 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_23, ARQUI_3, FUNÇÃO ELU

Arqui_3 - Elu - Erro:

Estatística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 0.548719	Média dos erros
2	std 0.126174	Desvio padrão
3	min 0.310953	Valor mínimo
4	25% 0.466022	Primeiro quartil (25%)
5	50% 0.556177	Mediana (50%)
6	75% 0.597176	Terceiro quartil (75%)
7	max 0.894684	Valor máximo

Arqui_3 - Elu - Acurácia:

Estatística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.974545	Média das acurácias
2	std 0.009719	Desvio padrão
3	min 0.945455	Valor mínimo
4	25% 0.963636	Primeiro quartil (25%)
5	50% 0.981818	Mediana (50%)
6	75% 0.981818	Terceiro quartil (75%)
7	max 0.981818	Valor máximo



FONTE: A autora (2024).

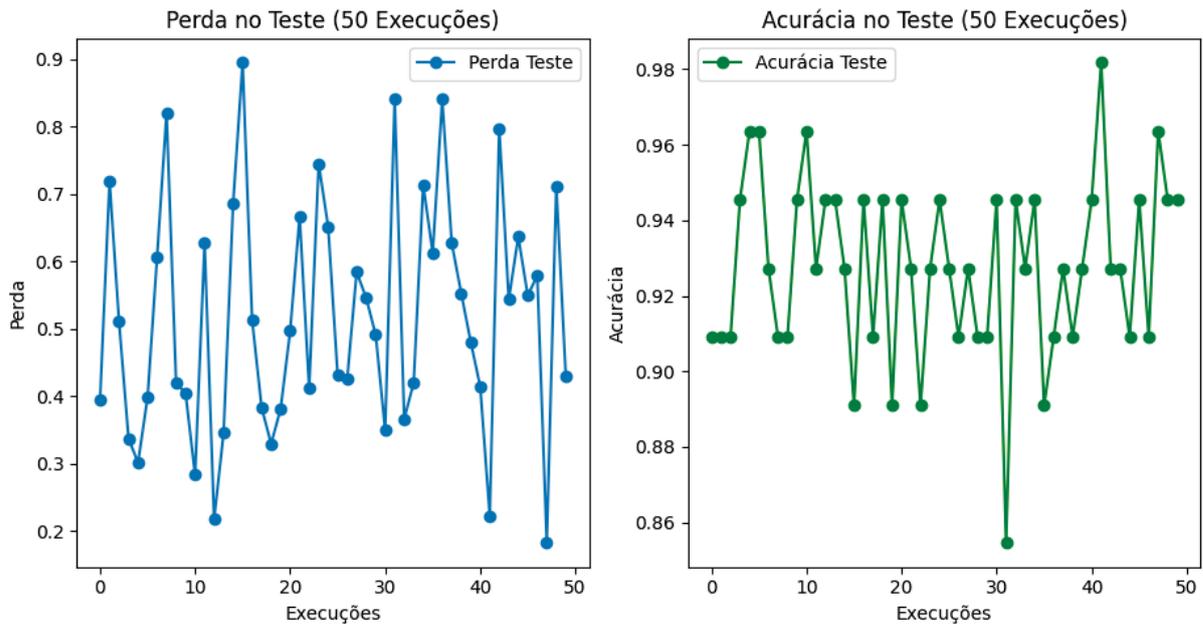
FIGURA 61 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_21, ARQUI_3, FUNÇÃO LEAKY RELU

Arqui_3 - Leaky ReLU - Erro:

Estatística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 0.517805	Média dos erros
2	std 0.175855	Desvio padrão
3	min 0.181919	Valor mínimo
4	25% 0.395354	Primeiro quartil (25%)
5	50% 0.503476	Mediana (50%)
6	75% 0.634436	Terceiro quartil (75%)
7	max 0.895689	Valor máximo

Arqui_3 - Leaky ReLU - Acurácia:

Estatística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.927636	Média das acurácias
2	std 0.023944	Desvio padrão
3	min 0.854545	Valor mínimo
4	25% 0.909091	Primeiro quartil (25%)
5	50% 0.927273	Mediana (50%)
6	75% 0.945455	Terceiro quartil (75%)
7	max 0.981818	Valor máximo



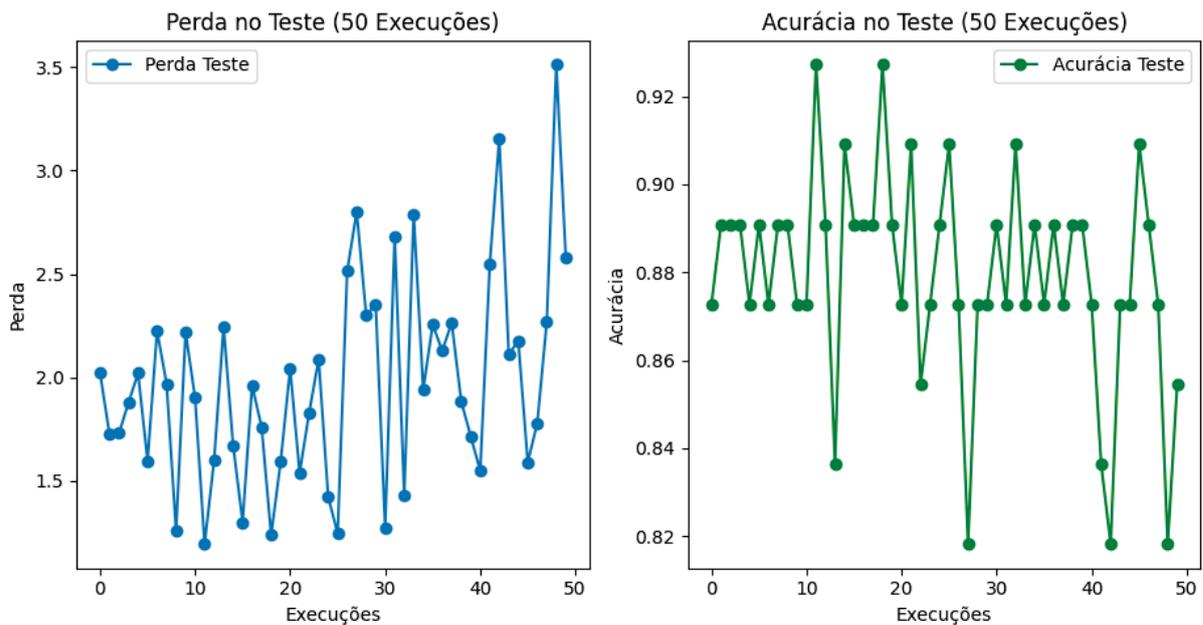
FONTE: A autora (2024).

FIGURA 62 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_22, ARQUI_3, FUNÇÃO LEAKY RELU

Arqui_3 - Leaky ReLU - Erro:

Arqui_3 - Leaky ReLU - Acurácia:

Estadística	Erro	Descrição	Estadística	Acurácia	Descrição
0	count 50.000000	Número de repetições	0	count 50.000000	Número de repetições
1	mean 1.977493	Média dos erros	1	mean 0.879636	Média das acurácias
2	std 0.504669	Desvio padrão	2	std 0.024056	Desvio padrão
3	min 1.194116	Valor mínimo	3	min 0.818182	Valor mínimo
4	25% 1.596936	Primeiro quartil (25%)	4	25% 0.872727	Primeiro quartil (25%)
5	50% 1.951894	Mediana (50%)	5	50% 0.881818	Mediana (50%)
6	75% 2.252319	Terceiro quartil (75%)	6	75% 0.890909	Terceiro quartil (75%)
7	max 3.512040	Valor máximo	7	max 0.927273	Valor máximo



FONTE: A autora (2024).

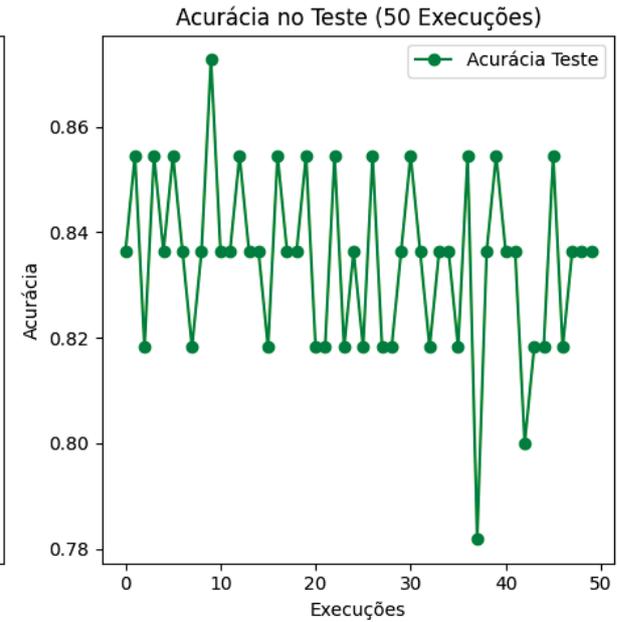
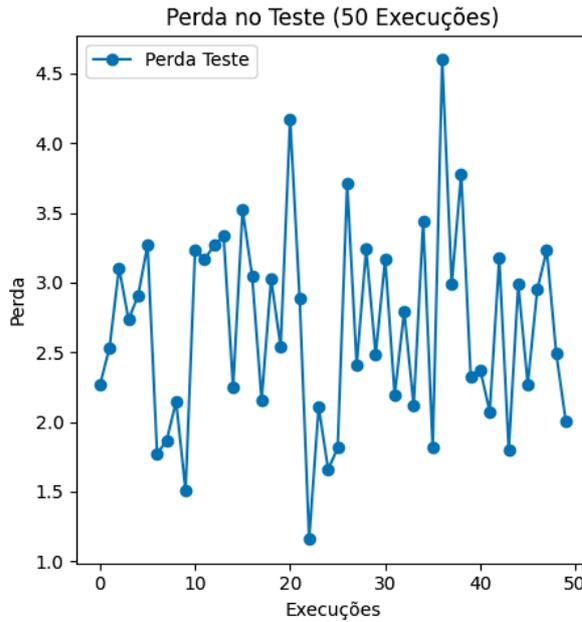
FIGURA 63 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_23, ARQUI_3, FUNÇÃO LEAKY RELU

Arqui_3 - Leaky ReLU - Erro:

Estadística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 2.677541	Média dos erros
2	std 0.710831	Desvio padrão
3	min 1.157715	Valor mínimo
4	25% 2.150105	Primeiro quartil (25%)
5	50% 2.637100	Mediana (50%)
6	75% 3.173283	Terceiro quartil (75%)
7	max 4.601268	Valor máximo

Arqui_3 - Leaky ReLU - Acurácia:

Estadística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.834545	Média das acurácias
2	std 0.016933	Desvio padrão
3	min 0.781818	Valor mínimo
4	25% 0.818182	Primeiro quartil (25%)
5	50% 0.836364	Mediana (50%)
6	75% 0.850000	Terceiro quartil (75%)
7	max 0.872727	Valor máximo



FONTE: A autora (2024).

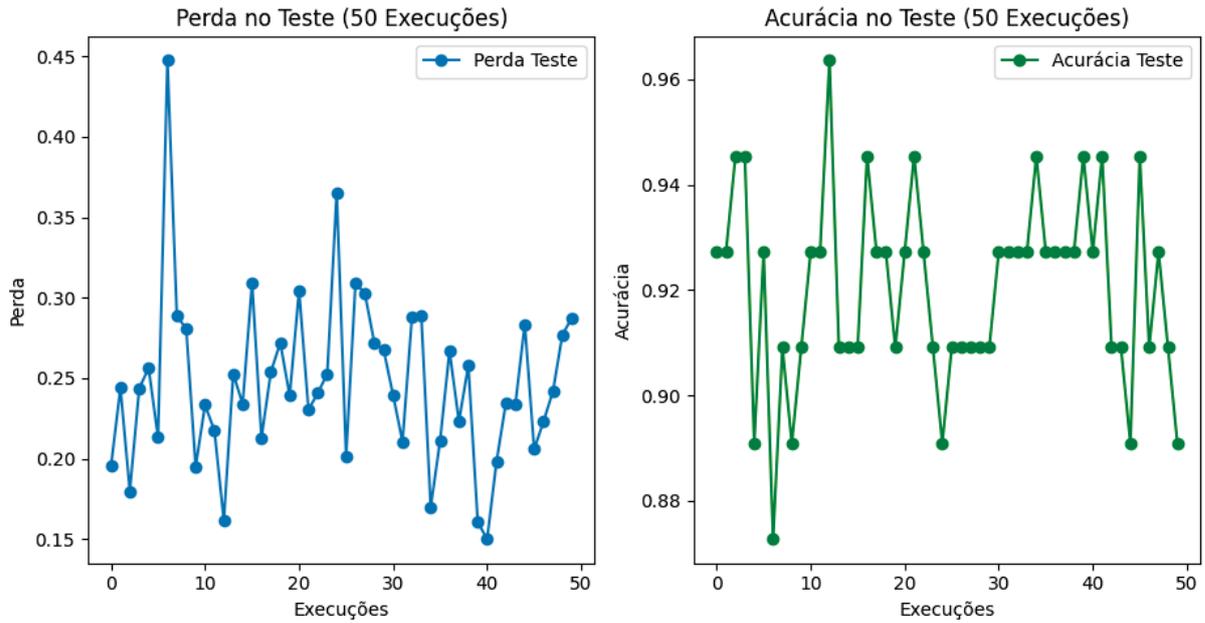
FIGURA 64 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_21, ARQUI_2, FUNÇÃO ELU E 100 ÉPOCAS

Arqui_2 - Elu - 100 Épocas - Erro:

Estadística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 0.246573	Média dos erros
2	std 0.052528	Desvio padrão
3	min 0.149922	Valor mínimo
4	25% 0.212998	Primeiro quartil (25%)
5	50% 0.241352	Mediana (50%)
6	75% 0.275752	Terceiro quartil (75%)
7	max 0.447629	Valor máximo

Arqui_2 - Elu - 100 Épocas - Acurácia:

Estadística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.920364	Média das acurácias
2	std 0.018326	Desvio padrão
3	min 0.872727	Valor mínimo
4	25% 0.909091	Primeiro quartil (25%)
5	50% 0.927273	Mediana (50%)
6	75% 0.927273	Terceiro quartil (75%)
7	max 0.963636	Valor máximo



FONTE: A autora (2024).

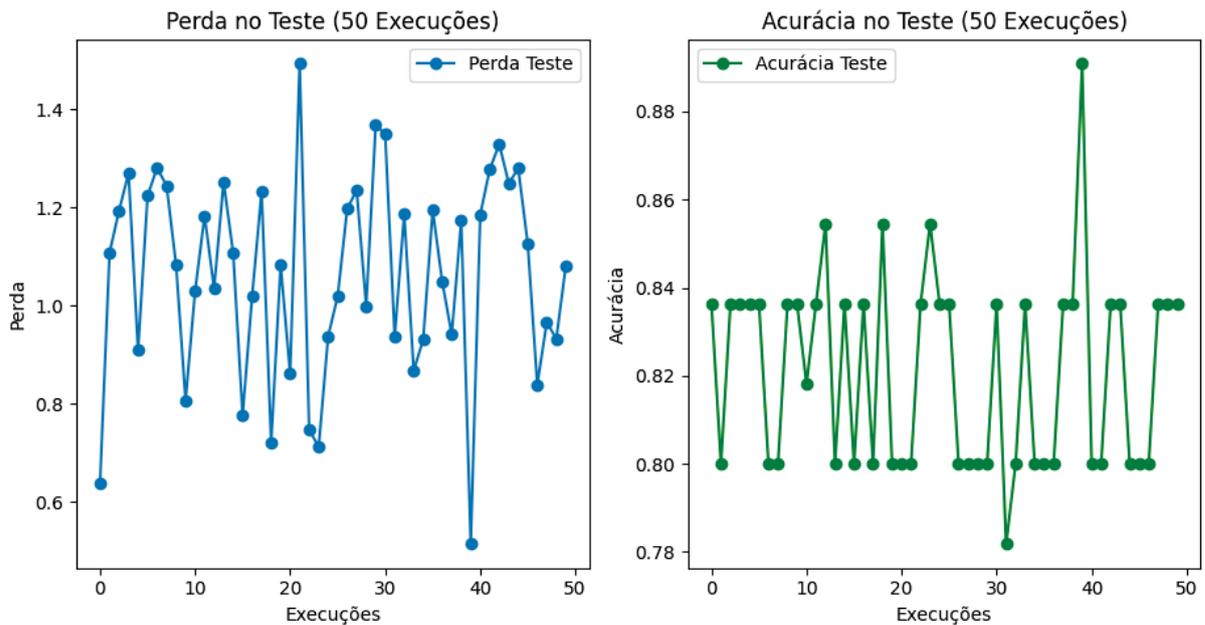
FIGURA 65 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_22, ARQUI_2, FUNÇÃO ELU E 100 ÉPOCAS

Arqui_2 - Elu - 100 Épocas - Erro:

Estadística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 1.063284	Média dos erros
2	std 0.208994	Desvio padrão
3	min 0.514374	Valor mínimo
4	25% 0.933302	Primeiro quartil (25%)
5	50% 1.082689	Mediana (50%)
6	75% 1.229928	Terceiro quartil (75%)
7	max 1.493142	Valor máximo

Arqui_2 - Elu - 100 Épocas - Acurácia:

Estadística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.821091	Média das acurácias
2	std 0.022452	Desvio padrão
3	min 0.781818	Valor mínimo
4	25% 0.800000	Primeiro quartil (25%)
5	50% 0.836364	Mediana (50%)
6	75% 0.836364	Terceiro quartil (75%)
7	max 0.890909	Valor máximo



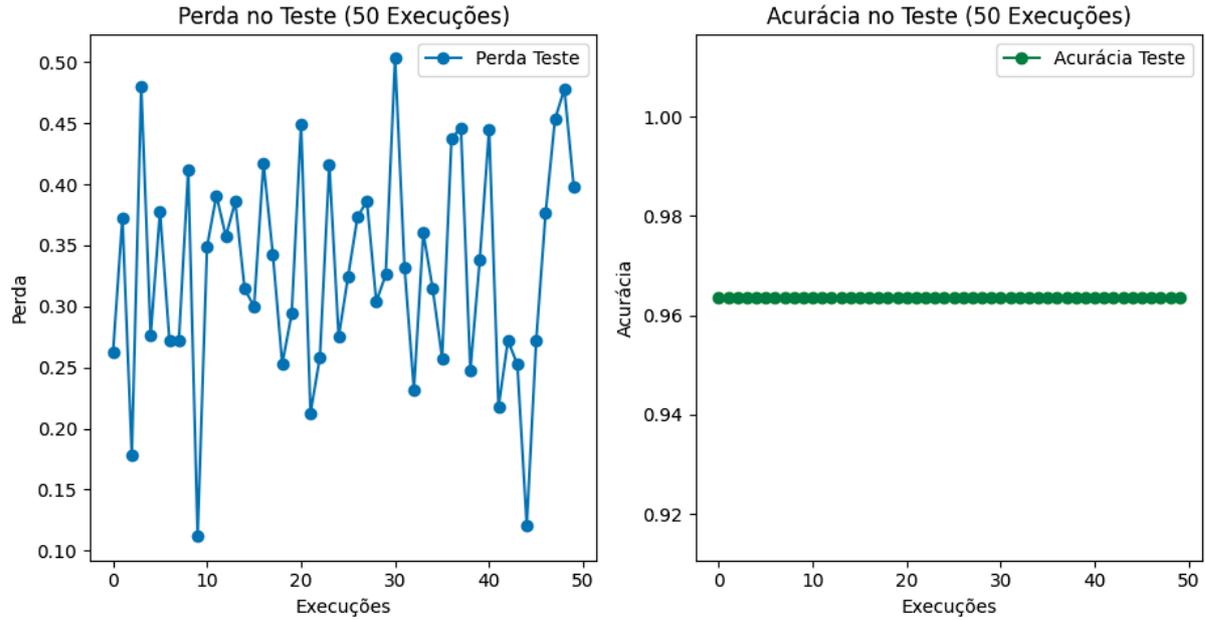
FONTE: A autora (2024).

FIGURA 66 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_23, ARQUI_2, FUNÇÃO LEAKY RELU E 100 ÉPOCAS

Arqui_2 - Leaky ReLU - 100 Épocas - Erro:

Arqui_2 - Leaky ReLU - 100 Épocas - Acurácia:

Estadística	Erro	Descrição	Estadística	Acurácia	Descrição		
0	count	50.000000	Número de repetições	0	count	50.000000	Número de repetições
1	mean	0.329946	Média dos erros	1	mean	0.963636	Média das acurácias
2	std	0.089884	Desvio padrão	2	std	0.000000	Desvio padrão
3	min	0.111756	Valor mínimo	3	min	0.963636	Valor mínimo
4	25%	0.271609	Primeiro quartil (25%)	4	25%	0.963636	Primeiro quartil (25%)
5	50%	0.329141	Mediana (50%)	5	50%	0.963636	Mediana (50%)
6	75%	0.389732	Terceiro quartil (75%)	6	75%	0.963636	Terceiro quartil (75%)
7	max	0.503214	Valor máximo	7	max	0.963636	Valor máximo



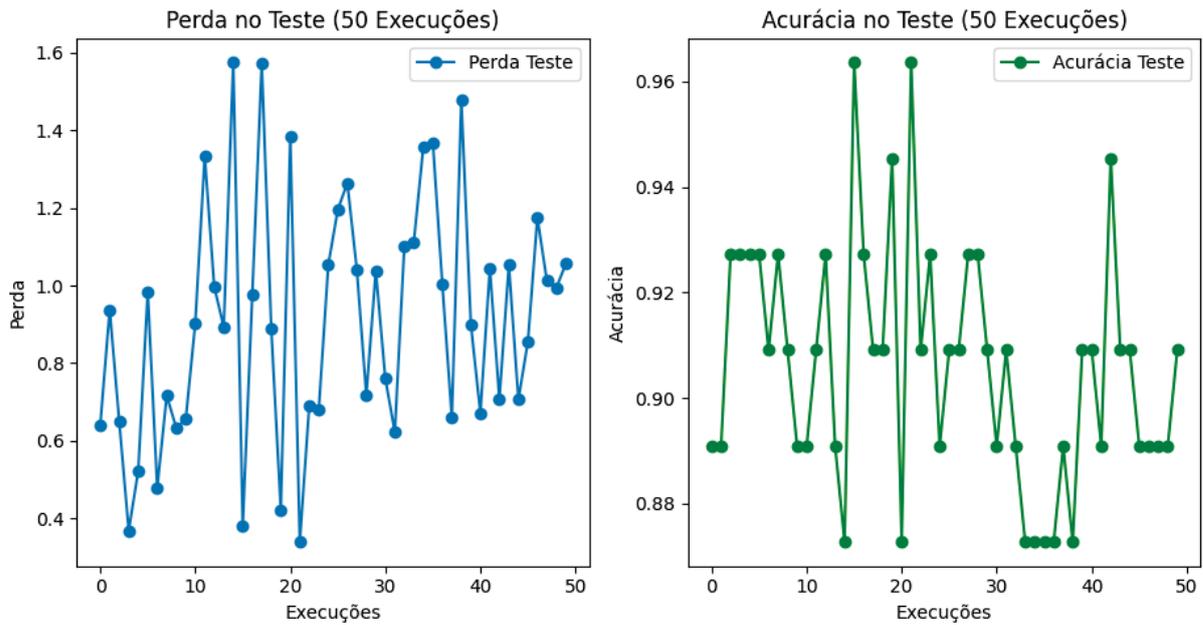
FONTE: A autora (2024).

FIGURA 67 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_21, ARQUI_2, FUNÇÃO ELU E 500 ÉPOCAS

Arqui_2 - Elu - 500 Épocas - Erro:

Arqui_2 - Elu - 500 Épocas - Acurácia:

Estadística	Erro	Descrição	Estadística	Acurácia	Descrição		
0	count	50.000000	Número de repetições	0	count	50.000000	Número de repetições
1	mean	0.911408	Média dos erros	1	mean	0.906182	Média das acurácias
2	std	0.312005	Desvio padrão	2	std	0.022751	Desvio padrão
3	min	0.339183	Valor mínimo	3	min	0.872727	Valor mínimo
4	25%	0.674000	Primeiro quartil (25%)	4	25%	0.890909	Primeiro quartil (25%)
5	50%	0.919692	Mediana (50%)	5	50%	0.909091	Mediana (50%)
6	75%	1.055992	Terceiro quartil (75%)	6	75%	0.927273	Terceiro quartil (75%)
7	max	1.575129	Valor máximo	7	max	0.963636	Valor máximo



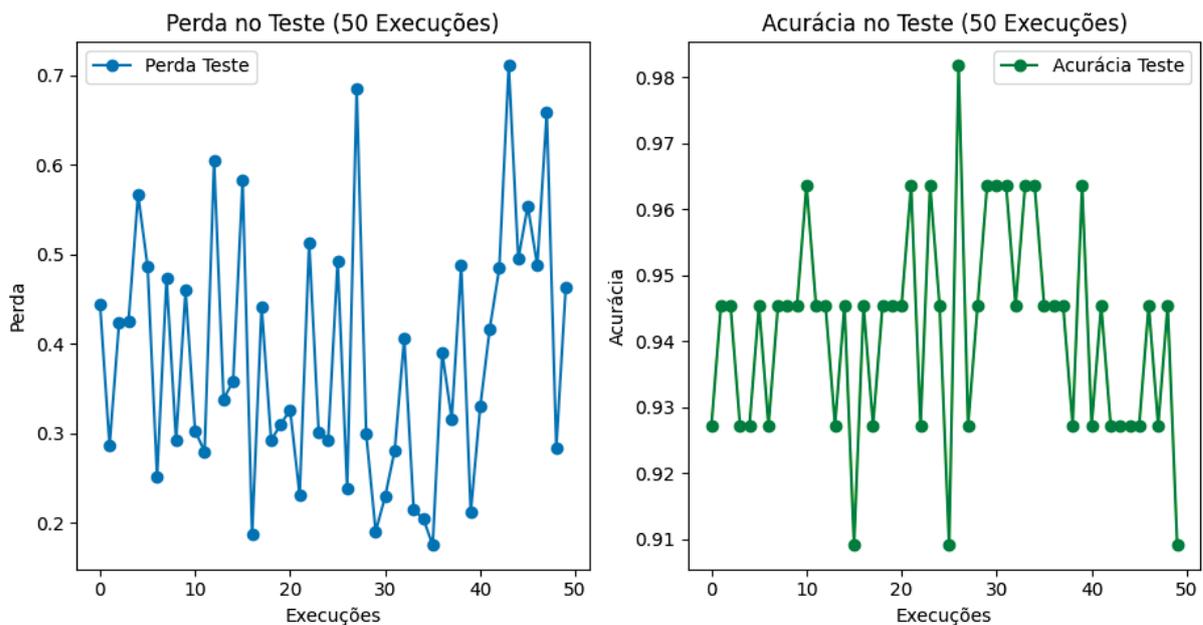
FONTE: A autora (2024).

FIGURA 68 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_22, ARQUI_2, FUNÇÃO ELU E 500 ÉPOCAS

Arqui_2 - Elu - 500 Épocas - Erro:

Arqui_2 - Elu - 500 Épocas - Acurácia:

Estadística	Erro	Descrição	Estadística	Acurácia	Descrição
0	count 50.000000	Número de repetições	0	count 50.000000	Número de repetições
1	mean 0.383433	Média dos erros	1	mean 0.941818	Média das acurácias
2	std 0.138592	Desvio padrão	2	std 0.016011	Desvio padrão
3	min 0.174912	Valor mínimo	3	min 0.909091	Valor mínimo
4	25% 0.284506	Primeiro quartil (25%)	4	25% 0.927273	Primeiro quartil (25%)
5	50% 0.348215	Mediana (50%)	5	50% 0.945455	Mediana (50%)
6	75% 0.485948	Terceiro quartil (75%)	6	75% 0.945455	Terceiro quartil (75%)
7	max 0.710960	Valor máximo	7	max 0.981818	Valor máximo



FONTE: A autora (2024).

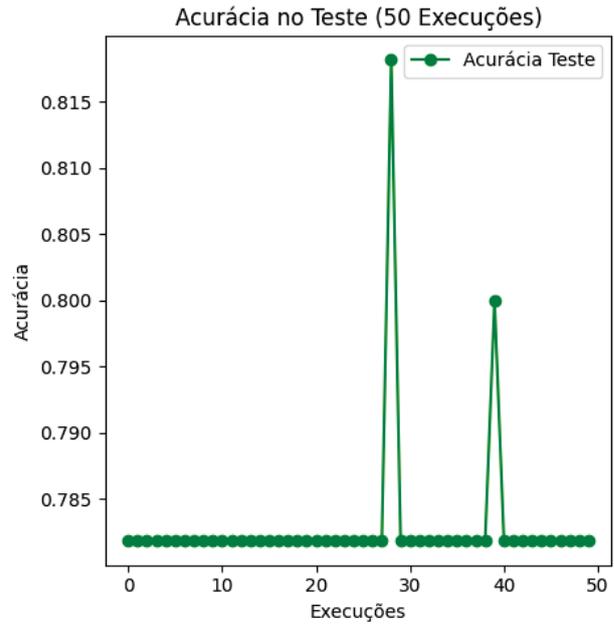
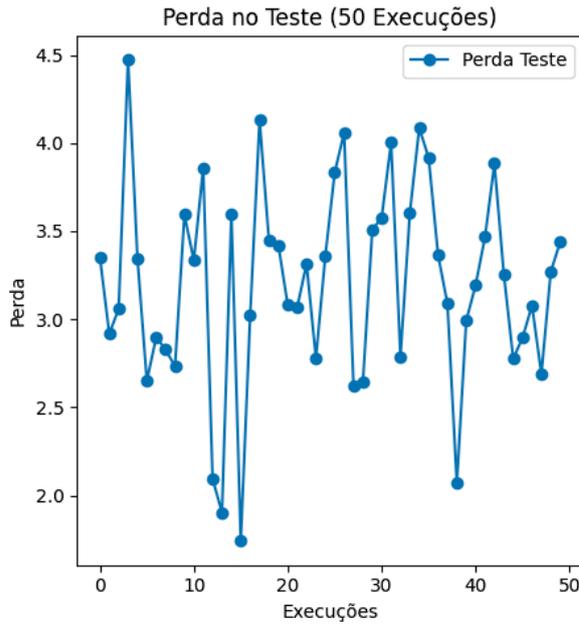
FIGURA 69 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_23, ARQUI_2, FUNÇÃO LEAKY RELU E 500 ÉPOCAS

Arqui_2 - Leaky ReLU - 500 Épocas - Erro:

Estatística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 3.202051	Média dos erros
2	std 0.577866	Desvio padrão
3	min 1.742319	Valor mínimo
4	25% 2.844514	Primeiro quartil (25%)
5	50% 3.263751	Mediana (50%)
6	75% 3.559788	Terceiro quartil (75%)
7	max 4.472553	Valor máximo

Arqui_2 - Leaky ReLU - 500 Épocas - Acurácia:

Estatística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.782909	Média das acurácias
2	std 0.005702	Desvio padrão
3	min 0.781818	Valor mínimo
4	25% 0.781818	Primeiro quartil (25%)
5	50% 0.781818	Mediana (50%)
6	75% 0.781818	Terceiro quartil (75%)
7	max 0.818182	Valor máximo



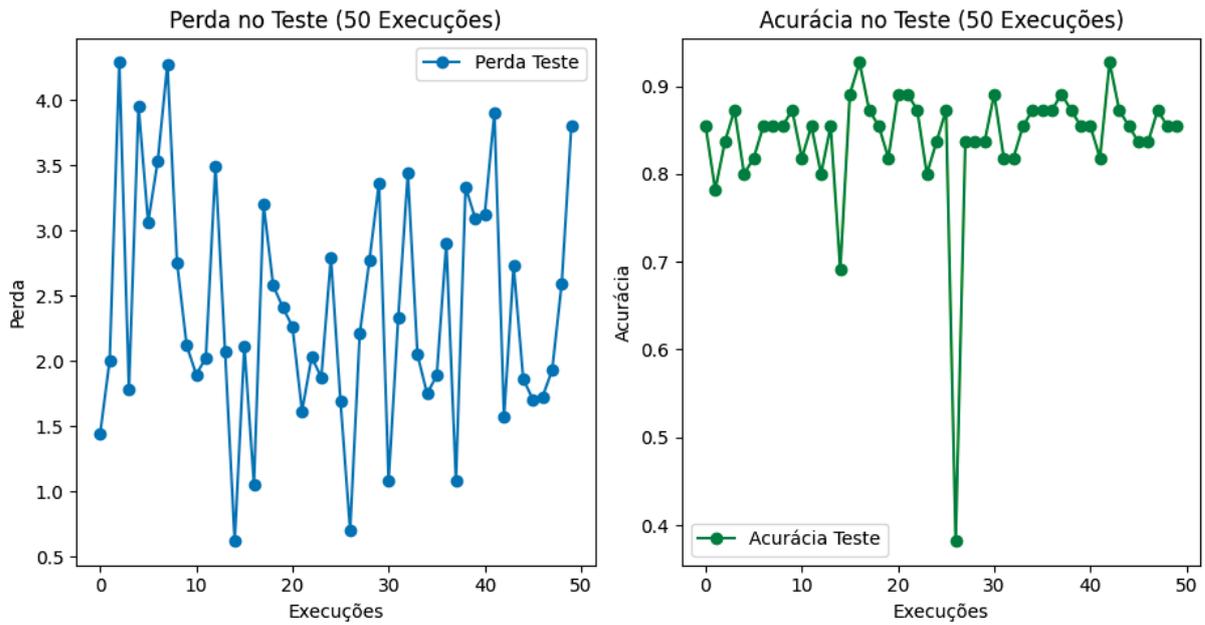
FONTE: A autora (2024).

FIGURA 70 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_21, ARQUI_2, FUNÇÃO ELU, 300 ÉPOCAS E TAXA DE APRENDIZAGEM 0,1

Arqui_2 - Elu - 300 Épocas - 0,1 Tx_Apren - Acurácia:

Estatística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 2.399413	Média dos erros
2	std 0.903866	Desvio padrão
3	min 0.620385	Valor mínimo
4	25% 1.806637	Primeiro quartil (25%)
5	50% 2.166189	Mediana (50%)
6	75% 3.087340	Terceiro quartil (75%)
7	max 4.291440	Valor máximo

Estatística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.840727	Média das acurácias
2	std 0.076397	Desvio padrão
3	min 0.381818	Valor mínimo
4	25% 0.836364	Primeiro quartil (25%)
5	50% 0.854545	Mediana (50%)
6	75% 0.872727	Terceiro quartil (75%)
7	max 0.927273	Valor máximo

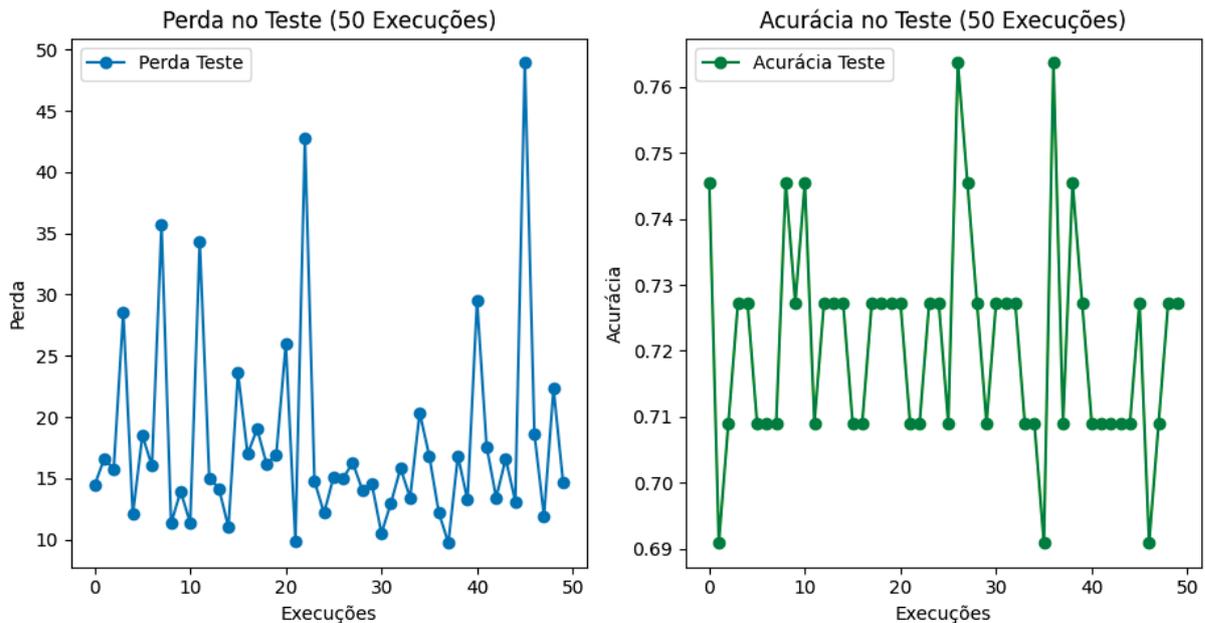


FONTE: A autora (2024).

FIGURA 71 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_22, ARQUI_2, FUNÇÃO ELU, 300 ÉPOCAS E TAXA DE APRENDIZAGEM 0,1

Arqui_2 - Elu - 300 Épokas - 0,1 Tx_Apren - Erro: Arqui_2 - Elu - 300 Épokas - 0,1 Tx_Apren - Acurácia:

Estadística	Erro	Descrição	Estadística	Acurácia	Descrição
0	count 50.000000	Número de repetições	0	count 50.000000	Número de repetições
1	mean 17.807713	Média dos erros	1	mean 0.721091	Média das acurácias
2	std 8.134489	Desvio padrão	2	std 0.016266	Desvio padrão
3	min 9.707702	Valor mínimo	3	min 0.690909	Valor mínimo
4	25% 13.271681	Primeiro quartil (25%)	4	25% 0.709091	Primeiro quartil (25%)
5	50% 15.444620	Mediana (50%)	5	50% 0.727273	Mediana (50%)
6	75% 18.272893	Terceiro quartil (75%)	6	75% 0.727273	Terceiro quartil (75%)
7	max 48.937469	Valor máximo	7	max 0.763636	Valor máximo

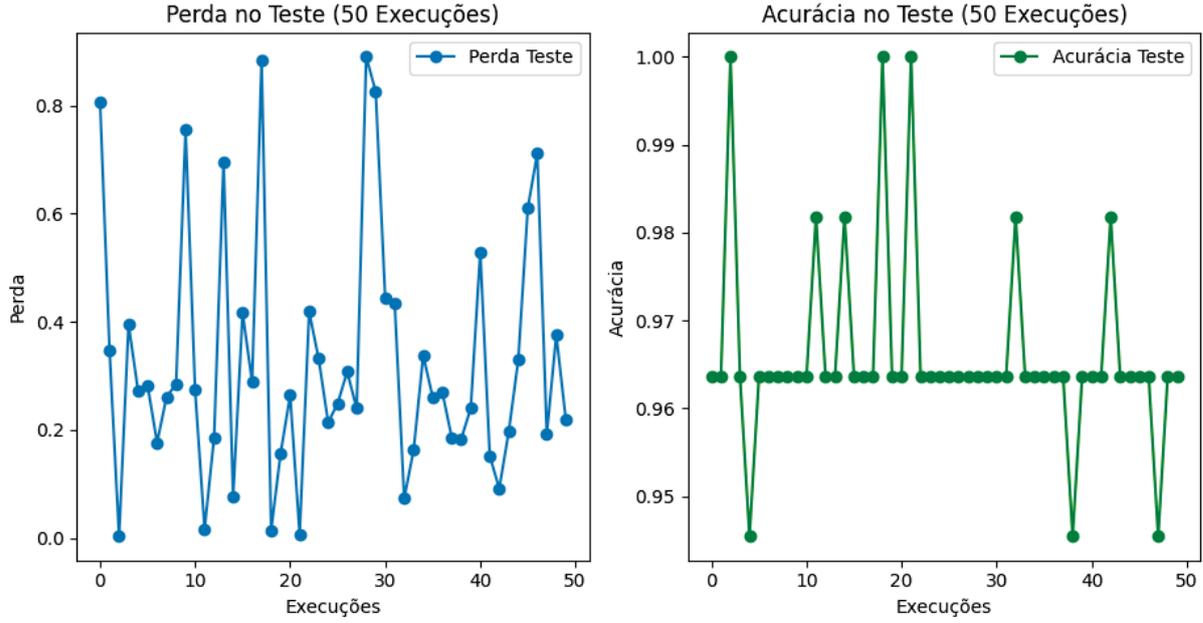


FONTE: A autora (2024).

FIGURA 72 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_23, ARQUI_2, FUNÇÃO LEAKY RELU, 300 ÉPOCAS E TAXA DE APRENDIZAGEM 0,1

Arqui_2 - Leaky ReLU - 300 Épocas - 0,1 Tx_Apren - Acurácia: Arqui_2 - Leaky ReLU - 300 Épocas - 0,1 Tx_Apren - Erro:

Estadística	Acurácia	Descrição	Estadística	Erro	Descrição
0	count 50.000000	Número de repetições	0	count 50.000000	Número de repetições
1	mean 0.966182	Média das acurácias	1	mean 0.326916	Média dos erros
2	std 0.011026	Desvio padrão	2	std 0.230643	Desvio padrão
3	min 0.945455	Valor mínimo	3	min 0.003009	Valor mínimo
4	25% 0.963636	Primeiro quartil (25%)	4	25% 0.186118	Primeiro quartil (25%)
5	50% 0.963636	Mediana (50%)	5	50% 0.271430	Mediana (50%)
6	75% 0.963636	Terceiro quartil (75%)	6	75% 0.411255	Terceiro quartil (75%)
7	max 1.000000	Valor máximo	7	max 0.890576	Valor máximo

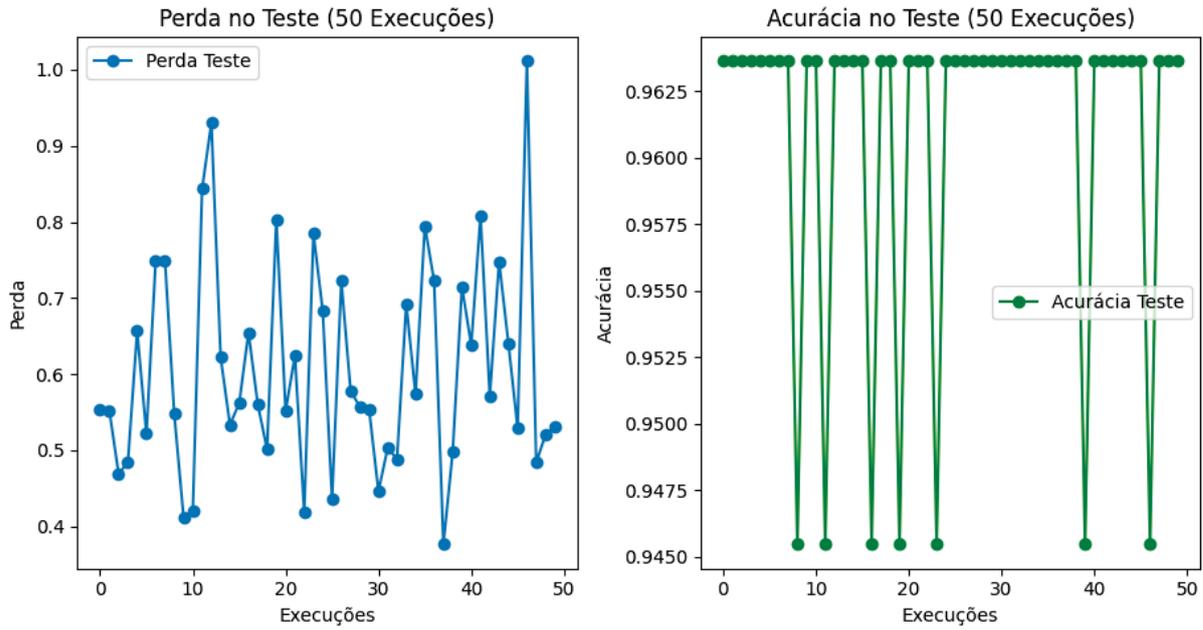


FONTE: A autora (2024).

FIGURA 73 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_21, ARQUI_2, FUNÇÃO ELU, 300 ÉPOCAS E TAXA DE APRENDIZAGEM 0,01

Arqui_2 - Elu - 300 Épocas - 0,01 Tx_Apren - Erro: Arqui_2 - Elu - 300 Épocas - 0,01 Tx_Apren - Acurácia:

Estadística	Erro	Descrição	Estadística	Acurácia	Descrição
0	count 50.000000	Número de repetições	0	count 50.000000	Número de repetições
1	mean 0.606551	Média dos erros	1	mean 0.961091	Média das acurácias
2	std 0.140032	Desvio padrão	2	std 0.006373	Desvio padrão
3	min 0.376416	Valor mínimo	3	min 0.945455	Valor mínimo
4	25% 0.507346	Primeiro quartil (25%)	4	25% 0.963636	Primeiro quartil (25%)
5	50% 0.561086	Mediana (50%)	5	50% 0.963636	Mediana (50%)
6	75% 0.708918	Terceiro quartil (75%)	6	75% 0.963636	Terceiro quartil (75%)
7	max 1.011760	Valor máximo	7	max 0.963636	Valor máximo

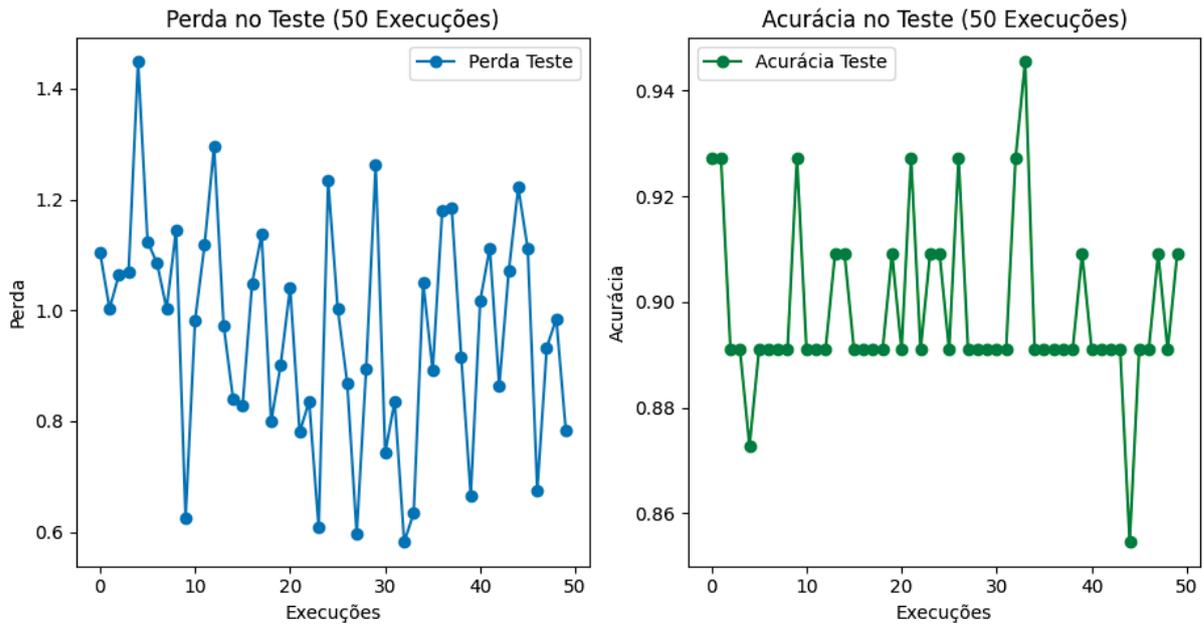


FONTE: A autora (2024).

FIGURA 74 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_22, ARQUI_2, FUNÇÃO ELU, 300 ÉPOCAS E TAXA DE APRENDIZAGEM 0,01

Arqui_2 - Elu - 300 Épokas - 0,01 Tx_Apren - Erro: Arqui_2 - Elu - 300 Épokas - 0,01 Tx_Apren - Acurácia:

Estadística	Erro	Descrição	Estadística	Acurácia	Descrição		
0	count	50.000000	Número de repetições	0	count	50.000000	Número de repetições
1	mean	0.963546	Média dos erros	1	mean	0.898182	Média das acurácias
2	std	0.200359	Desvio padrão	2	std	0.016011	Desvio padrão
3	min	0.581809	Valor mínimo	3	min	0.854545	Valor mínimo
4	25%	0.835932	Primeiro quartil (25%)	4	25%	0.890909	Primeiro quartil (25%)
5	50%	0.994046	Mediana (50%)	5	50%	0.890909	Mediana (50%)
6	75%	1.109451	Terceiro quartil (75%)	6	75%	0.909091	Terceiro quartil (75%)
7	max	1.448730	Valor máximo	7	max	0.945455	Valor máximo



FONTE: A autora (2024).

FIGURA 75 - RESULTADO DOS EXPERIMENTOS COMPUTACIONAIS DA RN_22, ARQUI_2, FUNÇÃO LEAKY RELU, 300 ÉPOCAS E TAXA DE APRENDIZAGEM 0,01

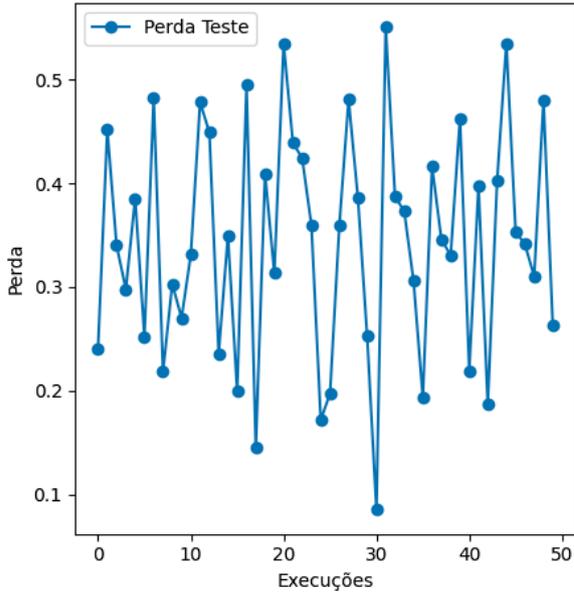
Arqui_2 - Leaky ReLU - 300 Épocas - 0,01 Tx_Apren - Erro:

Estadística	Erro	Descrição
0	count 50.000000	Número de repetições
1	mean 0.343706	Média dos erros
2	std 0.111020	Desvio padrão
3	min 0.085003	Valor mínimo
4	25% 0.254881	Primeiro quartil (25%)
5	50% 0.347528	Mediana (50%)
6	75% 0.422057	Terceiro quartil (75%)
7	max 0.550695	Valor máximo

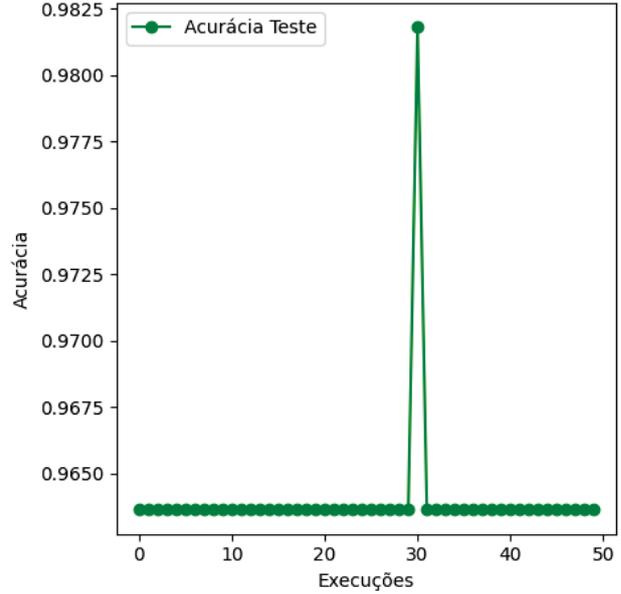
Arqui_2 - Leaky ReLU - 300 Épocas - 0,01 Tx_Apren - Acurácia:

Estadística	Acurácia	Descrição
0	count 50.000000	Número de repetições
1	mean 0.964000	Média das acurácias
2	std 0.002571	Desvio padrão
3	min 0.963636	Valor mínimo
4	25% 0.963636	Primeiro quartil (25%)
5	50% 0.963636	Mediana (50%)
6	75% 0.963636	Terceiro quartil (75%)
7	max 0.981818	Valor máximo

Perda no Teste (50 Execuções)



Acurácia no Teste (50 Execuções)



FONTE: A autora (2024).