



# **Máquinas se tornando humanos. Criação de uma rede neuronal artificial utilizando uma abordagem integrativa para prever o risco de diabetes**

**Madalena Domingos Francisco Sentimento Maicula**

Dissertação para obtenção de Grau de Mestre em  
**Ciências Biomédicas**  
(2º ciclo de estudos)

Orientador: Professor Doutor José António Menezes Felipe de Souza

Coorientador: Professor Doutor José Álvaro Nunes Pombo

Novembro, 2024



## **Declaração de Integridade**

Eu, Madalena Domingos Francisco Sentimento Maicula, que abaixo assino, estudante com o número de inscrição M12287 de Ciências Biomédicas da Faculdade da Saúde, declaro ter desenvolvido o presente trabalho e elaborado o presente texto em total consonância com o **Código de Integridades da Universidade da Beira Interior**.

Mais concretamente, afirmo não ter incorrido em qualquer das variedades de Fraude Académica, e que aqui declaro conhecer, que em particular atendi à exigida referenciação de frases, extratos, imagens e outras formas de trabalho intelectual, e assumindo assim na íntegra as responsabilidades da autoria.

Universidade da Beira Interior, Covilhã, 2024

A handwritten signature in blue ink that reads "Madalena D.F.S. Maicula". The signature is written in a cursive style with some capital letters.

Madalena D. F. S. Maicula

## **Agradecimentos**

Expresso minha profunda gratidão a Deus por me sustentar psicologicamente, proporcionando-me força para superar os desafios ao longo desta trajetória.

Minha gratidão se estende à minha amada família, em especial aos meus pais, Galiano Francisco Sentimento e Engrácia Domingos, meu dedicado marido, Zacarias Cardoso Kwanza Maicula, e meus preciosos filhos, Isabel Sentimento Cardoso e Wesley Leandro Sentimento Maicula. Agradeço a Deus por tê-los como pilares em minha vida.

Ao meu amado esposo, expresso minha profunda gratidão por financiar minha formação de mestrado e por todo o suporte financeiro necessário para a realização deste sonho. Sua ajuda incansável na superação de obstáculos e sua orientação no caminho para o sucesso são tesouros que guardarei no coração. Eu te amo, meu adorável companheiro de luta.

Ao meu orientador, Professor Doutor José António Menezes Felipe de Souza, pela oportunidade concedida, incentivo e paciência durante o desenvolvimento desta dissertação. Mesmo nos seus momentos de férias, esteve disponível para dialogar comigo, sem se importar com o horário de trabalho estabelecido. Confesso que me sinto honrada em trabalhar com o Doutor.

Ao meu coorientador, Professor Doutor José Álvaro Nunes Pombo, expresso minha profunda gratidão pela iniciativa e pelo privilégio de aceitar ser o mentor da parte prática deste trabalho. Seu comprometimento e esforço tem sido fundamentais para o meu progresso e sucesso. O senhor se tornou muito especial para nós e estou segura de que é especial para todos os alunos que passam nas mãos do Doutor.

Aos docentes do Curso de Ciências Biomédicas da UBI, pelos conhecimentos transmitidos e por despertarem em mim o interesse no campo da investigação. Estou segura ao dizer que foi uma honra ter-vos como professores e acredito que levarei esta experiência bem no fundo do meu coração.

## **Resumo**

A presente dissertação centra-se na exploração da temática "Máquinas agindo como Humanos" com um enfoque específico na investigação de tópicos de Inteligência Artificial (IA) utilizados por este fim. A dissertação visa compreender os avanços que possibilitam máquinas a replicarem ações humanas. Em um subtema específico, o foco direciona-se para a criação de uma rede neuronal artificial, que é uma temática de IA utilizando uma abordagem integrativa.

O estudo prático propõe a aplicação desta rede neuronal artificial no contexto da saúde, mais precisamente na previsão do risco de diabetes na população da Covilhã, com base nos fatores multidimensionais. A integração de variáveis abrangentes permitirá uma avaliação mais precisa, contribuindo para uma compreensão mais profunda dos padrões e fatores de risco associados à diabetes.

Ao investigar a interação entre Inteligência Artificial e saúde, a dissertação procura não apenas expandir o conhecimento científico, mas também oferecer uma ferramenta prática para avaliação de risco de diabetes, com potencial impacto positivo na saúde pública.

### **Palavras-chave**

Inteligência artificial, redes neurais artificiais, diabetes, aprendizagem de máquinas, computação, robôs.

## **Abstract**

This dissertation focuses on exploring the theme "machines acting like humans" with a specific focus on investigating Artificial Intelligence (AI) topics used for this purpose. The dissertation aims to understand the advances that enable machines to replicate human actions. In a specific subtopic, the focus is on creating an artificial neural network, which is an AI topic using an integrative approach.

The practical study proposes the application of this artificial neural network in the context of health, more precisely in predicting the risk of diabetes in the population of Covilhã, based on multidimensional factors. Integration of comprehensive variables will allow for more accurate assessment, contributing to a deeper understanding of the patterns and risk factors associated with diabetes.

By investigating the interaction between Artificial Intelligence and health, the dissertation seeks not only to expand scientific knowledge, but also to offer a practical tool for diabetes risk assessment, with a potential positive impact on public health.

## **Keywords**

Artificial intelligence, artificial neural networks, diabetes, machine learning, computing, robots.

# Índice

<b>Capítulo 1</b> .....	<b>13</b>
Introdução.....	13
1.1 Enquadramento .....	13
1.2 Motivação e objetivos.....	17
1.3 Estrutura e organização da dissertação .....	18
<b>Capítulo 2</b> .....	<b>19</b>
Diabetes.....	19
2.1 Fundamentação da diabetes .....	19
2.2 Fatores de riscos associados à diabetes .....	22
<b>Capítulo 3</b> .....	<b>25</b>
Inteligência artificial e seus respectivos tópicos.....	25
3.1 Fundamentos .....	25
3.2 Fundamentos de lógica fuzzy.....	32
3.3 Fundamento dos algoritmos genéticos .....	33
3.4 Breve história e evolução das redes neuronais .....	35
3.4.1 Redes neuronais artificiais e sua inspiração biológica.....	37
3.4.2 Neurónios artificiais: conceito, estrutura e funcionamento .....	37
3.4.3 Principais aplicações e casos de uso de redes neuronais .....	38
3.4.4 Arquiteturas e Topologias .....	40
3.4.5 Redes neuronais Feedforward: estrutura e funcionamento .....	40
3.4.6 Funções de Ativação .....	41
3.4.7 Conjuntos de treino, teste e validação em ambiente de aprendizagem máquina .....	44
3.5 Outras técnicas da inteligência artificial.....	46

<b>Capítulo 4 .....</b>	<b>48</b>
Materiais e Métodos .....	48
4.1 Apresentação .....	48
4.2 Ferramenta utilizada .....	48
4.3 Aquisição de dados e amostra selecionada .....	49
4.4 Pré-processamento dos dados colhidos .....	49
4.5 Estatística dos dados .....	51
4.6 Desenvolvimento do modelo (rede neuronal artificial) .....	63
<b>Capítulo 5 .....</b>	<b>67</b>
Análise dos resultados e discussão .....	67
5.1 Resultados .....	67
5.2 Discussão .....	67
<b>Capítulo 6 .....</b>	<b>69</b>
Conclusão.....	69
6.1 Considerações finais.....	69
6.1.1 Sugestões de trabalhos futuros .....	70
<b>Referências bibliográficas .....</b>	<b>71</b>
<b>Apêndice A: Questionários .....</b>	<b>A</b>
<b>Apêndice B: Tabela de treinamento .....</b>	<b>B</b>

## Lista de Figuras

FIGURA 1-1 PREVALÊNCIA DE DIABETES A NÍVEL MUNDIAL DE 2021 E PROJEÇÃO PARA 2045	16
FIGURA 1-2 PREVALÊNCIA DE DIABETES A NÍVEL DA EUROPA DE 2021 E PROJEÇÃO PARA 2045	16
FIGURA 3-1 REPRESENTAÇÃO DA SEMELHANÇA ENTRE O BRAÇO DE UM HOMEM E OS ROBÔS. [59]	27
FIGURA 3-2 ROBÔ SOPHIA IMITANDO EXPRESSÕES FACIAIS HUMANAS [70]	28
FIGURA 3-3 O CYBERONE QUE PROMETE RECONHECER AS EMOÇÕES, ANUNCIADO PELA XIAME [2]	29
FIGURA 3-4 AUTOMAÇÃO NO PROCESSO PRODUTIVO [50]	29
FIGURA 3-5 ROBÔ CIRÚRGICO USADO EM AMBIENTES HOSPITALARES [50]	30
FIGURA 3-6 ROBÔ DE REABILITAÇÃO E CIRÚRGICO, VINCI [25]	31
FIGURA 3-7 ROBÔ DE TELEMEDICINA [29]	31
FIGURA 3-8 REPRESENTAÇÃO NA FORMA DE CONJUNTOS DA ALTURA DE UMA PESSOA, SOB O PONTO DE VISTA DA LÓGICA CONVENCIONAL (À ESQUERDA) E DO DA LÓGICA <i>FUZZY</i> (À DIREITO) [62]	32
FIGURA 3-9 - DESENHO ESQUEMÁTICO DE NEURÓNIO BIOLÓGICO [4]	37
FIGURA 3-10 - MODELO DE UM NEURÓNIO ARTIFICIAL	38
FIGURA 3-11 - REDE NEURONAL TÍPICO DE UMA ARQUITETURA <i>FEEDFORWARD</i>	41
FIGURA 3-12 - FUNÇÃO DE ATIVAÇÃO SIGMOIDE	42
FIGURA 3-13 - TANGENTE HIPERBÓLICA (TANH).	42
FIGURA 3-14 - RELU (UNIDADE LINEAR RETIFICADA)	43
FIGURA 3-15 - FUNÇÃO DE ATIVAÇÃO LINEAR	43
FIGURA 3-16 - FUNÇÃO DE ATIVAÇÃO DEGRAU	44
FIGURA 4-1 - DISTRIBUIÇÃO DA FAIXA ETÁRIA DOS PARTICIPANTES	51
FIGURA 4-2 DISTRIBUIÇÃO DE ACORDO O SEXO	52
FIGURA 4-3 DISTRIBUIÇÃO DE ACORDO COM AS LOCALIDADES DA PESQUISA	52
FIGURA 4-4 ESTADO CIVIL DOS PARTICIPANTES	53
FIGURA 4-5 DISTRIBUIÇÃO DE ACORDO ALTURA DOS PARTICIPANTES	53
FIGURA 4-6 CATEGORIA ASSOCIADA AO PESO DOS PARTICIPANTES	54
FIGURA 4-7 DISTRIBUIÇÃO DAS MEDIDAS DA CINTURA DOS PARTICIPANTES	54
FIGURA 4-8 FREQUÊNCIA DE PRÁTICA DE ATIVIDADE FÍSICA REGULAR ENTRE OS PARTICIPANTES	55

FIGURA 4-9 FREQUÊNCIA DO CONSUMO DIÁRIO DOS ALIMENTOS NÃO SAUDÁVEIS DOS PARTICIPANTES	55
FIGURA 4-10 FREQUÊNCIA DE CONSUMO DIÁRIO DE ALIMENTOS SAUDÁVEIS DOS PARTICIPANTES	56
FIGURA 4-11 DISTRIBUIÇÃO DE USO DO TABAGISMO ENTRE OS PARTICIPANTES	56
FIGURA 4-12 DISTRIBUIÇÃO HÁBITO DE FUMAR REGULARMENTE ENTRE OS PARTICIPANTES	57
FIGURA 4-13 INCIDÊNCIA DE ALTERAÇÕES NOS NÍVEIS DE GLICOSE ENTRE OS PARTICIPANTES	57
FIGURA 4-14-DISTRIBUIÇÃO DE ACORDO COM OS NÍVEIS DE GLICOSE DURANTE A GRAVIDEZ	58
FIGURA 4-15 DISTRIBUIÇÃO DOS DADOS DE ACORDO O USO DOS NÍVEIS DE PRESSÃO	58
FIGURA 4-16 DISTRIBUIÇÃO DA FAIXA DE PRESSÃO ARTERIAL QUE MELHOR DESCREVE A CONDIÇÃO DOS INDIVÍDUOS	59
FIGURA 4-17 INCIDÊNCIA DE DIABETES ENTRE OS PARENTES DO 1º GRAU	60
FIGURA 4-18 INCIDÊNCIA DE DIABETES ENTRE OS PARENTES DO 2º GRAU	60
FIGURA 4-19 DISTRIBUIÇÃO DE ACORDO O NÚMERO OS PACIENTES COM E SEM DIABETES	61
FIGURA 4-20 DISTRIBUIÇÃO DE ACORDO COM O TIPO DE DIABETES DIAGNOSTICADO	61
FIGURA 4-21 DISTRIBUIÇÃO DE ACORDO COM A FAIXA DE RENDIMENTO SALARIAL	62
FIGURA 4-22 PARTILHA DE EXPERIÊNCIA SOBRE DIABETES DOS PARTICIPANTES	62
FIGURA 4-23 - DIAGRAMA DE FLUXO. FONTE DO AUTOR	63

## **Lista de Tabelas**

TABELA 3-1 DESENVOLVIMENTO/MARCO HISTÓRICO SOBRE REDES NEURONAIS ARTIFICIAIS E PESQUISADORES ENVOLVIDOS.....	36
TABELA 3-2 ALGORITMOS DE TREINAMENTOS DE UMA RNA NO MATLAB .....	45
TABELA 4-1 CODIFICAÇÃO DE VARIÁVEIS CATEGÓRICA.....	50
TABELA 4-2 – DISTRIBUIÇÃO DOS CONJUNTOS DE DADOS (TOTAL: 161) .....	65
TABELA 4-3 DIFERENTES TIPOS DE ARQUITETURAS NEURONAIS E SUAS RESPETIVAS TAXAS DE SUCESSOS.....	66
TABELA APÊNDICE B-1 TREINAMENTO E INDIVÍDUOS EM FALHAS. ....	B

## Nomenclatura

### Índices inferiores:

$x_1$	Primeira entrada
$x_2$	Segunda entrada
$f(x)$	Função de ativação
$W_n$	Peso de outros valores
$b$	Bias
$x_n$	N Entradas
mg/dl	Miligramas por decilitros

### Simbologia grega:

$\Sigma$	Somatório
$\int$	Função de ativação Entrada

### Acrónimos:

IA	Inteligência Artificial
RNA	Redes Neurais Artificiais
RNR	Redes Neurais Recorrentes
TanH	Tangente Hiperbólica
ReLU	Unidade Linear Retificada
OND	Observatório Nacional da Diabetes
DM	Diabetes <i>Mellitus</i>
IDF	Federação Internacional de Diabetes
OMS	Organização Mundial da Saúde
TOTG	Teste de Tolerância à Glicose
RI	Resistência à Insulina
DMG	Diabetes <i>Mellitus</i> Gestacional
TNF	Fator de Necrose Tumoral
SBD	Sociedade Brasileira de Diabetes
LMS	Least Mean Squares ou Mínimos Quadrados Médios
RNAs	Redes Neurais Artificiais
Ags	Algoritmos Genéticos
CDC	Centro de Controlo e prevenção de doenças

# Capítulo 1

Este capítulo tem como propósito enquadrar o conteúdo abordado nesta dissertação. Inicia-se com uma breve introdução para contextualizar o tema, seguida pela apresentação dos aspectos motivacionais que levaram ao desenvolvimento deste trabalho e seus objetivos, por fim, será exposta a estrutura desta dissertação bem como uma breve descrição do que é abordado em cada capítulo.

## Introdução

### 1.1 Enquadramento

A inteligência artificial (IA) é um campo de conhecimento associado à linguagem e à inteligência, ao raciocínio, à aprendizagem e à resolução de problemas. A IA propicia a simbiose entre o humano e as máquinas ao acoplar sistemas inteligentes artificiais ao corpo humano (prótese cerebral, braço biônico, células artificiais, joelho inteligente, coração artificial, pâncreas artificiais e similares) e a interação entre o humano e a máquina como duas espécies distintas conectadas (homem-aplicativos, homem-algoritmos de IA) [38]. A IA tem sido tema de pesquisa em diversas áreas tal como na computação, linguística, filosofia, saúde, neurociência, entre outras.

Portanto, IA é entendida como um ramo da ciência da engenharia e da computação que se propõe a desenvolver sistemas que simulem a capacidade humana de percepção de um problema, identificando seus componentes para, com isso, resolver problemas e propor/tomar decisões [5].

O avanço da IA tem levado ao desenvolvimento de máquinas cada vez mais capazes de emular comportamentos humanos, um fenômeno que podemos chamar de: “máquinas agindo como humanos”. Desta área de estudo e sua aplicação envolve a criação de sistemas computacionais que podem realizar tarefas que normalmente exigem inteligência humana, como entender linguagem natural, reconhecer padrões visuais, tomar decisões complexos e até interagir emocionalmente com pessoas. Desde assistentes virtuais que nos ajudam com tarefas cotidianas a robôs que realizam trabalhos físicos ou sociais, a capacidade das máquinas de imitar o comportamento humano está transformando diversos setores da sociedade.

Em Russell e Norving [57], a inteligência artificial é definida como um agente capaz de perceber o seu meio ambiente e realizar ações com expectativa de selecionar uma ação que maximiza o seu desempenho. Alguns investigadores atribuem a primeira referência sobre a inteligência artificial ao matemático e cientista da computação Alan Turing, no seu famoso artigo “*computing Machinery and intelligence*” (1950) no qual propôs o desafio “*Can*

*Machines Think?*” (As máquinas podem pensar?). Há mais de 7 décadas, Alan Turing afirmou que podemos esperar que as máquinas vão competir com todos os humanos na área de inteligência.

Para ilustrar como as máquinas estão cada vez mais avançadas para realizar tarefas anteriormente executadas por humanos, utilizou-se a patologia diabetes. Esta doença é uma epidemia que regista grandes incidências e é responsável pela diminuição da qualidade de vida de muitas pessoas. Sabendo que, conhecer os fatores de riscos associados a diabetes é considerado complexo e importante, o presente trabalho propõe a construção de um modelo baseado em aprendizagem de máquina e extração de padrões, capaz de suportar esses fatores.

Em 2014, a prevalência de diabetes entre adultos com 18 anos ou mais foi de 8,5%. No ano de 2019, a diabetes foi responsável por 1,5 milhão de óbitos, sendo que 48% destas mortes ocorreram antes dos 70 anos. Além disso, 460.000 mortes relacionadas a doenças renais foram atribuídas à diabetes, e aproximadamente 20% das mortes cardiovasculares foram causadas pelo aumento da glicemia [4]. De acordo com a Organização Mundial da Saúde (OMS), no período de 2000 a 2019, houve um aumento de 3% nas taxas de mortalidade padronizadas por idade devido à diabetes. Nos países de rendimento médio-baixo, a taxa de mortalidade devido à diabetes experimentou um aumento de 13%.

Portugal destaca-se entre os países europeus com uma das mais elevadas taxas de prevalência de diabetes. Segundo os dados mais recentes do Observatório Nacional da Diabete (OND), aproximadamente 13,3% da população portuguesa, entre 20 e 79 anos, é afetada pela diabetes, totalizando mais de um milhão de indivíduos [1]. Considerando esse contexto, surge a seguinte questão: Quais são os fatores multidimensionais associados a um maior risco de diabetes na população da Covilhã, considerando a aplicação de redes neuronais artificiais como ferramenta de análise?

Assim sendo, este estudo parte do princípio de que a inteligência artificial oferece abordagens atrativas para prever o risco de diabetes. A utilização de redes neuronais artificiais na análise desses fatores pode desvendar padrões complexos e relações não lineares, fornecendo informações valiosas para a compreensão e previsão desta condição na comunidade local.

A prevalência da diabetes representa um desafio significativo para os sistemas de saúde em todo o mundo, abrangendo a população portuguesa e, de maneira mais específica, os habitantes da Covilhã. Nesse contexto, é essencial explorar abordagens inovadoras que aprimorem a compreensão e previsão desta condição. A inteligência computacional, os seus tópicos em particular a aplicação de redes neuronais artificiais, destaca-se como uma ferramenta promissora para analisar, prever os fatores multidimensionais associados ao risco de diabetes na comunidade local. Espero com esta dissertação, poder gerar contribuições

científicas, acerca de um modelo de rede neuronal artificial capaz de prever os riscos da diabetes na população do município da Covilhã, com base nos fatores multidimensionais, ajudar direta e indiretamente na tomada de decisões dos profissionais de saúde e outras áreas do conhecimento. Notando que, teremos uma visão epidemiológica sobre a diabetes na população em estudo, fornecendo uma revisão geral sobre o papel evolutivo das tecnologias, com ênfase na inteligência artificial e seus subtemas, no apoio à tomada de decisões.

A inteligência artificial engloba diversos subtemas ou tópicos que capacitam máquinas a imitarem comportamento humano. Estes permitem que as máquinas aprendam dados, reconhecem padrões complexos, lidam com incertezas nos dados e desenvolvem sistemas computacionais mais poderosos e eficientes. Ao longo da história, a inteligência artificial tem evoluído bastante, impulsionado por avanços tecnológicos e uma compreensão mais profunda dos processos cognitivos humanos, impactando diversas áreas do conhecimento.

Um dos grandes desafios da inteligência artificial é o desenvolvimento de sistemas que se baseiam nas decisões humanas, estas aplicações são encontradas com frequência na inteligência artificial aplicada na medicina, sendo desenvolvidas a partir de software que capacitam as máquinas a agirem de maneira semelhante aos seres humanos. Desde a aprendizagem de máquina até as redes neurais, sistemas de lógica *fuzzy* e robótica, esses são apenas alguns dos elementos-chave que impulsionam o desenvolvimento da inteligência artificial. Não é de hoje que a tecnologia da informação como IA e especificamente as redes neurais é utilizada para estudos na área da saúde.

Em De Lima et al. [20] utilizou-se as redes neurais artificiais com o objetivo de identificar os tipos de anomalias congênitas do sistema nervoso por meio de um modelo de tomada de decisão. O estudo teve uma natureza tecnológica e retrospectiva, utilizando dados secundários provenientes do sistema de informação de nascidos vivos, com posterior identificação das anomalias realizada por meio de redes neurais artificiais, no período de 2009 a 2014, no estado da Paraíba, no Brasil. Foi utilizada uma rede neuronal artificial com uma arquitetura *feedforward* com múltiplas camadas escondidas, com algoritmo de treino *backpropagation*. O estudo mostrou sucesso ao fornecer um modelo capaz de identificar os tipos de anomalias congênitas do sistema nervoso, podendo ser útil no apoio à tomada de decisões por gestores públicos e profissionais de saúde.

Em Barreto et al. [6], utilizou-se esta técnica para projetar e treinar uma rede neuronal artificial, a qual poderá ser usada na área oncológica, visando permitir o suporte à decisão clínica auxiliando no diagnóstico e encaminhamento apropriado de pacientes com suspeita de câncer cervical, utilizando os dados disponíveis dos mesmos e de fatores de risco da doença. O trabalho, teve como objetivo geral desenvolver uma rede neuronal artificial para o auxílio no diagnóstico de Câncer de Cervical. Alcançando grande sucesso na pesquisa.

São vários estudos encontrados na literatura em que foram utilizadas as RNA (rede neuronal artificial) para resolver uns possíveis problemas, os quais até o momento têm demonstrado grande êxito. Isso destaca a importância de utilizar as mesmas em problemas como a doença de diabetes, que tem afetado muito a população a nível mundial e visto que as prevalências e as projeções têm demonstrado um aumento significativo até 2045, tal como mostram as Figuras 1.1 e 1.2.




Figura 1-1 Prevalência de Diabetes a nível mundial de 2021 e projeção para 2045

Certamente, para lidar com o aumento ou reduzir estas projeções de prevalências de 12,2% a nível mundial, são necessárias estudar medidas de saúde públicas e aproveitar os sistemas tecnológicos que visam a previsão e o controlo da doença, visto que conhecer os fatores de riscos permitem que as pessoas adaptem um comportamento em relação a um estilo de vida mais apropriado.

A Figura 1-2 apresenta projeções da prevalência das diabetes a nível da Europa, mostrando um aumento significativo de 10,4% até 2045, que é preocupante e constitui mais uma razão pela qual é importante abordar este assunto.




Figura 1-2 Prevalência de Diabetes a nível da Europa de 2021 e projeção para 2045

## 1.2 Motivação e objetivos

Observando a elevada taxa das diabetes descritas em várias plataformas, como observatórios nacionais, site da Organização Mundial de Saúde (OMS), bem como a convivência com as pessoas próximas com esta condição de saúde, levou-se a necessidade de desenvolver métodos capaz de prever o risco das diabetes com base em redes neuronais, sobre forma de ajudar em um pré-diagnóstico precoce e intervenções nos estágios iniciais da doença, promovendo melhoria no estilo de vida, principalmente para indivíduos com alto risco. Além disso, o método desenvolvido pode auxiliar os profissionais da saúde na identificação dos indivíduos com maior probabilidade de desenvolver diabetes, permitindo ou possibilitando assim intervenções preventivas e um acompanhamento mais próximo. Podendo contribuir na redução da incidência e do impacto da diabete no local em estudo.

Ao criar este método de prever os riscos das diabetes, os médicos podem adaptarem os tratamentos e gestão da saúde de cada indivíduo considerando os fatores de riscos específicos previstos pela rede neuronal e consolidando com outros métodos já existentes.

Com a evolução da inteligência artificial, as máquinas têm se destacado na realização de tarefas que anteriormente eram exclusivamente realizadas pelos seres humanos. Esta transformação levanta questões intrigantes sobre o futuro, especialmente quando consideramos o potencial das máquinas em realizar quase todas as tarefas que os humanos podem fazer. Por um lado, esta evolução traz benefícios significativos, já que as máquinas podem executar tarefas com maior eficiência e precisão do que os humanos. Particularmente na medicina, a inteligência artificial tem demonstrado capacidade para diagnósticos mais precisos e desenvolvimento de tratamentos mais eficazes. Nesse contexto, as redes neuronais desempenham um papel crucial, especialmente na área da saúde, onde podem ser utilizadas para prever doenças, personalizar tratamentos e melhorar a qualidade de vida dos pacientes. Portanto, o presente trabalho tem como objetivo geral, refletir sobre a capacidade das máquinas de imitar e reproduzir os comportamentos humanos. Para isso, foi desenvolvida uma rede neuronal artificial utilizando uma abordagem integrativa para prever o risco de diabetes na população da Covilhã, considerando fatores multidimensionais. Além disso, é realizado uma breve revisão sistemática dos tópicos essenciais sobre inteligência artificial, de maneira a contextualizar o estudo em questão.

Portanto, são abordados detalhadamente aspetos relevantes sobre a doença em estudo, visando uma compreensão aprofundada. Este enfoque tem como objetivo primordial fornecer uma base sólida para a criação do modelo, facilitando assim a interpretação dos dados e otimizando a eficácia do mesmo.

Foi conduzido uma recolha de dados reais por intermédio de um questionário relacionado às diabetes dirigido à população da Covilhã, seguindo da avaliação e validação do modelo desenvolvido, com objetivo de uma possível divulgação do mesmo posteriormente.

### **1.3 Estrutura e organização da dissertação**

Esta dissertação está dividida em seis capítulos, cada um deles explicando assuntos diferentes.

Este capítulo consiste numa breve introdução com intuito de fazer um enquadramento da dissertação, seguida das motivações pelas quais é elaborado e os objetivos a serem realizados. Por último, é apresentado de que modo este documento está organizado em termos de estruturação.

O segundo capítulo destaca os aspetos relacionados com a diabetes, visto que esta é a patologia do estudo prático, com o objetivo de garantir maior segurança na implementação de determinados aspetos na rede neuronal artificial criada.

O terceiro capítulo descreve alguns dos tópicos da inteligência artificial com destaque para as redes neuronais de maneira a proporcionar um melhor entendimento como foram desenvolvidas, como funcionam, especialmente na área da saúde. Tendo em conta que se trata de uma ferramenta que simula o comportamento do cérebro, ou especificamente das redes neuronais humanas.

O quarto capítulo descreve a metodologia e materiais utilizados para o desenvolvimento da rede neuronal artificial, assim como a sua implementação.

O quinto capítulo descreve os resultados, bem como as suas discussões.

Por último, no sexto capítulo são enunciadas as conclusões finais do trabalho realizado, além de serem apresentadas ideias e direções de investigação para o desenvolvimento de trabalhos futuros.

## Capítulo 2

O propósito deste capítulo é fornecer uma compreensão das diabetes, suas características, fisiopatologia, complicações, métodos de diagnóstico, tratamento, prevenção e fatores de riscos. Este conhecimento é fundamental para o desenvolvimento desta dissertação, que se concentra na criação de uma rede neuronal artificial para prever o risco das diabetes na população de Covilhã, com base em fatores multidimensionais. Ao compreender esses aspectos, acredita-se que podemos desenvolver um modelo preciso e eficaz.

### Diabetes

#### 2.1 Fundamentação da diabetes

A diabetes *mellitus* (DM) é um distúrbio metabólico caracterizado por hiperglicemia como resultado da secreção e ação anormais da insulina [13]. A diabetes *mellitus* engloba um grupo de doenças que têm em comum a presença de hiperglicemia. Esta pode resultar de anomalias na secreção de insulina, de anomalias na sua ação nos tecidos periféricos ou de ambas [45]. Portanto, também é conceituada como um distúrbio no qual a concentração sérica (do sangue) de glicose (um açúcar simples) encontra-se anormalmente elevada, pois o organismo não libera ou não utiliza a glicose de modo adequado. Esta concentração sérica de açúcar (glicose) varia durante o dia, aumentando após uma refeição e retornando ao normal em 2 horas. Normalmente, a glicose encontra-se entre 70 e 110 miligramas por decilitro (mg/dl) de sangue pela manhã, após uma noite de jejum. Também se encontra inferior a 120 a 140 miligramas por decilitro (mg/dl), 2 horas após o consumo de alimentos ou de líquidos que contenham açúcares ou outros carboidratos [8].

De acordo com o relatório da Federação Internacional de Diabetes (IDF) [20] para 2021, 537 milhões de adultos vivem com diabetes, o que representa cerca de 10% da população total. Prevê-se que este número aumente para 643 milhões até 2030 e 783 milhões até 2045. Além disso, a IDF relatou que mais de 75% dos adultos com diabetes vivem em países de baixa e média renda. A taxa de prevalência de diabetes em países de alta renda, países de renda média e países de baixa renda é de 11,1%, 10,8% e 5,5%, respectivamente.

As estimativas de diabetes para 2021 mostram uma prevalência crescente de diabetes por idade. Prevêem-se tendências semelhantes para 2045. Os adultos entre os 20 e os 24 anos têm a prevalência mais baixa (2,2% em 2021). Prevê-se que a prevalência do diabetes seja de 24,0% em indivíduos com idade entre 75 e 79 anos em 2021 e aumente para 24,7% em 2045.

Em 2021, aproximadamente 6,7 milhões de mortes entre adultos com idades entre 20 e 79 anos foram atribuídas ao diabetes ou suas complicações [27].

Nem sempre é fácil classificar o tipo de diabetes do indivíduo, no entanto mais importante que a sua classificação é perceber o mecanismo patogénico subjacente e o seu tratamento efetivo. A classificação da diabetes engloba duas vertentes complementares. A classificação clínica reflete os vários níveis de hiperglicemia. Todos os doentes podem, em qualquer circunstância, ser classificados de acordo com o estágio clínico e esta hiperglicemia pode alterar-se com o tempo, dependendo da extensão da doença. A classificação etiológica reflete o facto do defeito ou anomalia que pode desencadear a doença, pode ser identificado em qualquer estágio do desenvolvimento de diabetes, independentemente do valor de glicemia. Atualmente a diabetes possui quatro classificações clínicas, Diabetes *mellitus* tipo 1, Diabetes *mellitus* tipo 2, outros tipos específicos e a diabetes *mellitus* gestacional, onde estas são classificadas pela etiologia e não pelo tratamento, como é proposto pela Organização Mundial da Saúde (OMS).

Portanto, a diabetes tipo 1 tem ocorrência de 5 -10% no total dos casos, onde neste tipo de diabetes ocorre a destruição das células  $\beta$  do pâncreas. É uma doença que ocorre principalmente em crianças e adolescentes, nos adultos ela pode também ocorrer, mas em qualquer um dos casos ocorre a destruição progressiva das células que geralmente leva a deficiência absoluta de insulina endógena [14]. O termo tipo I, vai indicar destruição das células beta que eventualmente leva à um estágio de deficiência absoluta de insulina, fazendo com que o paciente necessite administrar doses de insulina para prevenir cetoacidose, coma e até mesmo a morte [17]. Esta forma de diabetes tem uma forte componente hereditária e caracteriza-se por uma necessidade terapêutica com insulina variável com o tempo.

A diabetes *mellitus* tipo 2 (DM2) é um problema de saúde pública mundial, considerado uma pandemia, pois afeta grande parte da população, sobrecarregando e onerando os sistemas de saúde pública [70]. O diagnóstico correto e precoce do diabetes é uma das medidas que pode contribuir para a diminuição da incidência e prevalência dos casos e dos impactos desta doença, sendo extremamente importante para o tratamento eficaz e preventivo de suas complicações [69]. As principais causas deste tipo de DM estão relacionadas a hábitos alimentares inadequados, excesso de peso, sedentarismo, triglicédeos elevados e hipertensão [43].

Portanto, o diagnóstico do DM2 baseia-se nos sintomas característicos apresentados pelo paciente e na deteção de alterações em três parâmetros, que são os testes laboratoriais utilizados para o diagnóstico, como glicemia em jejum, teste oral de tolerância à glicose (TOTG) e hemoglobina glicada [11].

Por isso, a DM2 deve ser investigada em adultos de qualquer idade, que estejam com excesso de peso e que tenham um ou mais fatores de risco. Para aqueles sem tais fatores de risco, os testes devem começar aos 45 anos e, se normais, devem ser repetidos pelo menos a cada 3 anos [47].

As alterações no metabolismo materno são importantes para suprir as demandas do feto. Durante a segunda metade da gestação, o desenvolvimento de resistência à insulina (RI) é resultado de adaptação fisiológica, mediada pelos hormônios placentários anti insulínicos, para garantir o aporte adequado de glicose ao feto. Entretanto, algumas mulheres que engravidam com algum grau de RI, como nos casos de sobrepeso/obesidade, obesidade central e síndrome dos ovários policísticos, este estado fisiológico de RI pode ser potencializado nos tecidos periféricos. Paralelamente, impõem-se a necessidade fisiológica de maior produção de insulina, e a incapacidade do pâncreas em responder à RI fisiológica ou à sobreposta, favorece o quadro de hiperglicemia de intensidade variada, caracterizando o DMG [56].

A diabetes gestacional é caracterizada pela hiperglicemia diagnosticada no período gestacional, apresenta uma intensidade variada, onde está se resolve principalmente no período pós-parto. De acordo com a OMS, recomenda-se detetar este tipo de diabetes com os mesmos procedimentos de diagnóstico empregados fora da gravidez, condenando como diabetes gestacional valores referidos fora da gravidez como indicativos de diabetes ou de tolerância à glicose diminuída [17].

Quanto à fisiopatologia, durante a gravidez normal, observa-se o desenvolvimento progressiva de RI, começando no meio da gestação e progride durante o terceiro trimestre. Hormônios e adipocinas secretados pela placenta, incluindo fator de necrose tumoral (TNF)- $\alpha$ , lactogênio placentário humano e hormônio de crescimento placentário humano são possíveis causas de RI na gravidez. Além disso, o aumento do estrogênio, da progesterona e do cortisol durante a gravidez contribui para uma perturbação do equilíbrio glicose-insulina. Para compensar a RI periférica durante a gravidez, a secreção de insulina aumenta no pâncreas da mulher. O desenvolvimento da diabetes *mellitus* gestacional (DMG) ocorre quando o pâncreas da mulher não secreta insulina suficiente para acompanhar o estresse metabólico da RI. Além disso, o aumento da deposição de gordura materna, a diminuição do exercício e o aumento da ingestão calórica contribuem para este estado de relativa intolerância à glicose.

Segundo Silva et al. [63], aproximadamente 7% das gestações apresentam alguma complicação oriunda da DMG, resultando assim em mais de 200 mil casos por ano, um percentual bastante relevante e que merece atenção principalmente em relação aos riscos aos quais as gestantes e seus bebês ficam expostos.

O diagnóstico da DMG, de acordo com a Sociedade Brasileira de Diabetes (SBD) e a Organização Mundial de Saúde (OMS), deve ser realizado por meio do teste de tolerância à glicose (TOTG), que deverá ser realizado entre 24 e 26 semanas de gestação em todas as grávidas. Considera-se diabetes gestacional as gestantes nas quais o teste de tolerância à glicose apresentar valor igual ou superior a 92, 180 e 153mg/dl (miligrama decilitro). Nos

casos em que o resultado tenha valores iguais ou superiores a 180 e 153 mg/dl, na primeira e segunda hora é de suma importância que a gestante seja encaminhada para o acompanhamento gestacional de risco até o parto [39].

De acordo com Araújo, et al. [4] o controle glicêmico rotineiro e o acompanhamento frequente com um profissional de saúde numa maternidade neonatal são fatores importantes para a redução de danos decorrentes da DMG à gestante. Desta forma deve identificar diagnósticos para elaboração de um plano de cuidados que contribuirá na prevenção de complicações, através de orientações, acompanhamento e incentivo à manutenção do tratamento [34]. O plano de cuidados deve priorizar, um melhor controle da nutrição por meio de uma alimentação balanceada, encorajamento à monitoração, a prática de atividades físicas como caminhadas, hidroginástica, o uso correto das medicações, bem como o esclarecimento de toda a enfermidade à paciente e sua família [4].

A terapia nutricional é a primeira opção de escolha pelos profissionais para o tratamento das gestantes com DMG, já a prática de exercício físico leve a moderado só deve ser incentivada na ausência de contraindicações obstétricas. De acordo com estudo de Dos Santos, et al. [22], o tratamento com insulina exógena será indicado quando a dieta e o exercício físico não conseguirem normalizar a glicemia da gestante.

## **2.2 Fatores de riscos associados à diabetes**

A complexidade de diabetes *mellitus* reside em sua natureza multifatorial, onde a interação de fatores genéticos, ambientais e comportamentais contribui para o seu desenvolvimento. Entre esses fatores, os quais chamamos de fatores de riscos, desempenham um papel crucial, influenciando a predisposição de um indivíduo ao desenvolvimento da doença.

Pretende com esta subseção, explorar os fatores de risco associados as diabetes *mellitus*, destacando tanto os fatores de risco modificáveis e não modificáveis. Para melhor enquadramento da dissertação e ter um melhor direcionamento na criação da rede neuronal artificial.

Acredita-se que ao analisar os fatores de riscos associado às Diabetes, é possível identificar padrões e tendências que podem orientar políticas de saúde pública, programas de educação e campanhas de prevenção.

Nesta abordagem, examinamos de forma específica uma ampla gama de fatores de risco associados aos diferentes tipos de diabetes, visto que estes são classificados etiologicamente como diabetes do tipo 1,2, gestacional entre outros, isso serve de base para nossos resultados e conclusão.

Segundo o Centro de Controle e Prevenção de Doença (CDC) [27], acredita-se que o diabetes do tipo 1 seja causado por uma reação imunológica (corpo ataca a si mesmo por engano). Os fatores de risco para diabetes do tipo 1 não são tão claros quanto para diabetes do tipo 2. Portanto, os fatores de risco conhecidos incluem o histórico familiar (ter pai, irmão ou irmã com diabetes tipo 1), idade (a diabetes do tipo 1 surge em qualquer idade, mas geralmente se desenvolve em crianças, adolescentes ou adultos jovens).

Notando que as diabetes do tipo 1 que atinge menos de 5% da população a nível mundial, vendo aumentar ligeiramente cada vez mais nos jovens.

Para diabetes do tipo 2, são associados fatores de riscos como, presença de pré diabetes, acima do peso, ter 45 anos ou mais, ter um pai, irmã ou irmão com diabetes do tipo 2, se são fisicamente ativos menos de 3 vezes por semana, ter ou já teve diabetes gestacional (diabetes durante gravidez) ou deu à luz um bebê que pesava mais de 4 quilos.

O estilo de vida está diretamente relacionado com a incidência de diabetes *mellitus* do tipo 2 e da síndrome metabólica, a obesidade e o sedentarismo aumentam drasticamente esse risco. Alguns estudos mostraram que pessoas que consomem uma dieta rica em cereais integrais e ácidos graxos polinsaturados, associada ao consumo reduzido de ácidos graxos trans e de alimentos com elevado índice glicêmico, apresentam riscos diminuídos para o desenvolvimento de diabetes *mellitus*.

O sedentarismo é um fator de risco para a obesidade tão importante quanto o consumo de dieta inadequada, e possui uma relação direta e positiva com o aumento da incidência de diabetes *mellitus* do tipo 2 em adultos, independentemente do Índice de Massa Corporal (IMC) ou de história familiar de diabetes *mellitus*.

A Diabetes *Mellitus* Gestacional (DMG) é considerado como um problema de saúde pública, isto por ser uma doença que apresenta disfunção metabólica bastante comum no período gestacional [7]. Segundo o mesmo autor, descreveu um estudo realizado por americanos que acompanharam o rastreamento de rotina de 3.744 gestantes com DMG, os resultados encontrados demonstraram que negras e hispânicas tiveram o risco aumentado em desenvolver a doença, quando equiparado com brancas, assim além de outros fatores, como: a idade materna mais avançada, ganho de peso excessivo durante a gestação, sobrepeso ou obesidade, síndrome dos ovários policísticos, história prévia de bebês grandes ( $\geq 4$  kg), história familiar de diabetes em parentes de 1º grau, história de diabetes gestacional na mãe da gestante, hipertensão arterial sistêmica na gestação e gestação múltipla.

O diagnóstico precoce das gestantes portadoras de DMG é de suma importância, por isso é imprescindível que os exames sejam realizados ainda no primeiro trimestre, quando se inicia o pré-natal. Pois através da identificação de alterações na glicemia, é possível orientar a

gestante acerca dos cuidados que deve adotar durante a gravidez, ressaltando a importância de minimizar os efeitos adversos que causam alterações metabólicas sobre o binômio mãe-filho, assim como também de identificar quais são as mulheres que apresentam um maior risco de desenvolver diabetes futuramente [33].

Lembrando que, mulheres com DMG têm uma incidência aumentada de distúrbios hipertensivos durante a gravidez, incluindo hipertensão gestacional, pré-eclâmpsia e eclâmpsia. Existe um risco aumentado de polidrâmnio que pode aumentar o risco de trabalho de parto prematuro. O crescimento fetal excessivo continua sendo uma importante preocupação perinatal no DMG. As consequências do crescimento fetal excessivo incluem trauma no nascimento, morbidade materna por cesariana, distocia de ombro e hipoglicemia neonatal. Outras morbidades neonatais que potencialmente ocorrem com mais frequência em bebês de mulheres com DMG incluem hiperbilirrubinemia, hipocalcemia, eritema e síndrome do desconforto respiratório. As complicações a longo prazo do DMG incluem diabetes e doenças cardiovasculares nas mães e obesidade. A maioria das gestantes com diagnóstico de DMG apresenta normalidade na tolerância aos carboidratos após puerpério. No entanto, é extremamente importante que estas mulheres sejam acompanhadas no pós-parto, em intervalos regulares com objetivo de detectar se a paciente ainda apresenta os níveis de glicose descompassados, principalmente em relação ao preparo desta para uma futura gestação, uma vez que a DMG pode novamente surgir à medida que a mulher volta a engravidar, por isso os cuidados se estendem até mesmo no pós-parto [68].

## Capítulo 3

O propósito deste capítulo é fornecer uma compreensão de como as máquinas estão a tornar-se capazes de imitar comportamentos humanos, com foco em tópicos de inteligência artificial como a lógica *fuzzy*, algoritmos genéticos e redes neurais artificiais. Abordaremos as suas definições e inspiração biológica, fornecendo uma breve história e evolução destas tecnologias. Além disso, destacaremos suas aplicações, com ênfase especial na área da saúde. Acredita-se que este capítulo é de grande importância na realização desta dissertação, visto que incluirá uma aplicação prática sobre as redes neurais artificiais com objetivo de prever os riscos da diabetes na população de Covilhã, com base em fatores multidimensionais. Ao compreender esses aspetos técnicos e teóricos, acredita-se que podemos desenvolver um modelo preciso e eficaz.

### Inteligência artificial e seus respetivos tópicos

#### 3.1 Fundamentos

A inteligência artificial (IA) tem avançado de forma impressionante, transformando-se em uma área essencial da ciência e da tecnologia, com objetivo de replicar e até mesmo superar as capacidades humanas. Esse progresso está a fazer com que as máquinas se tornem cada vez mais humanizadas, capazes de realizar tarefas complexas que requerem não apenas cálculos precisos, mas também uma compreensão mais profunda do mundo que nos rodeia.

A inteligência artificial é o ramo da ciência da computação que estuda os sistemas cujo funcionamento assemelha-se ao pensamento humano, com capacidade de aprendizagem e o armazenamento de conhecimento [21].

As tecnologias de IA, como redes neurais artificiais, algoritmos genéticos e lógica *fuzzy*, desempenham um papel crucial nesse processo de humanização das máquinas. Esses *softwares* permitem que as máquinas aprendam com dados, adaptam-se a novas informações e tomem decisões em situações incertas ou ambíguas, características que são intrinsecamente humanas [61].

Por exemplo, as redes neurais artificiais, inspiradas na estrutura do cérebro humano, são capazes de reconhecer padrões em imagens ou sons, diagnosticar doenças com uma precisão muitas das vezes superior à dos humanos, identificar padrões em exames laboratoriais, prever riscos de doenças e complicações. Elas oferecem um apoio crucial na personalização dos tratamentos e na gestão dos cuidados de saúde.

Apesar de serem todos classificados como inteligência computacional, os três tópicos abordados nesta dissertação são distintos em sua essência e na maneira como resolvem problemas. Portanto, posteriormente serão apresentados, de maneira resumida, os conceitos básicos de cada uma destas técnicas, ilustrando como as máquinas estão cada vez mais agindo como humanos.

Quando se fala de máquinas agindo como humanos, referimos a sistemas e tecnologias que imitam ou replicam habilidades humanas. Incluindo a robótica que é um campo da engenharia e ciência da computação que envolve a criação e programação de robôs, máquinas projetadas para realizar tarefas que normalmente exigiriam intervenção humana. A robótica é uma área que procura imitar, replicar ou até mesmo superar a capacidade humana por meio de máquinas. Devido a elevada quantidade de aplicações que surgem, não temos uma única forma de classificação de uma máquina ou robô. Portanto, podemos classificar os robôs de acordo com o grau de interatividade com agentes externos. Então, podemos classificar os vários tipos que são robôs industriais, robôs humanoides, robôs de serviços e robôs médicos [64].

- **Robôs Industriais**

No início da década de 60, surgiram os primeiros robôs industriais. A tecnologia desenvolvida por George Devol e Joe Engelberger permitiu que os robôs fossem programados para realizar tarefas, tornando-os mais úteis e acessíveis. George Devol recebeu, em 1961, a patente do primeiro braço robótico programável controlado digitalmente. Desta tecnologia deu origem às primeiras máquinas de uso industrial, que foram usadas para trabalhos previsíveis e repetitivos, como a montagem de componentes. Joe Engelberger fundou a empresa *Unimation Inc.* e foi o primeiro a comercializar destas máquinas, ganhando, por esse motivo, o título de “Pai da Robótica” [54].

A maioria dos robôs atuais é do tipo "manipuladores" industriais. Um robô manipulador tem as características de um braço humano – ombro, antebraço, cotovelo, braço, mão e dedos. A sua aplicação na indústria tem sido cada vez mais frequente, pois os robôs permitem uma maior precisão no que toca ao manuseamento de objetos e a sua capacidade de se adaptar ao ambiente de trabalho e as condições de produção. Além disso, as máquinas são capazes de trabalhar por horas consecutivas e com maior rapidez do que os humanos. Outras aplicações de robôs manipuladores incluem a limpeza de edifícios, tarefas de montagem, soldadura, pintura, manuseamento de materiais e embalagem. A Figura 3.1 ilustra a comparação de um braço de um robô e do humano.




Figura 3-1 Representação da semelhança entre o braço de um homem e os robôs. [59]

Os Robôs industriais são utilizados principalmente em ambientes industriais para realizar tarefas repetitivas, perigosas ou que exigem alta precisão. Esses robôs, como os manipuladores industriais, são frequentemente vistos em linhas de montagem, soldagem, pintura e embalagem de produtos. Por exemplo, os primeiros robôs industriais, desenvolvidos por George Devol e Joe Engelberger, foram programados para montar componentes de forma precisa e eficiente, revolucionando a indústria automotiva.

Com o avanço da tecnologia, os robôs industriais agora possuem maior flexibilidade e inteligência, permitindo-lhes adaptar-se a diferentes tarefas e condições de trabalho. Estas máquinas são capazes de operar continuamente sem fadiga, aumentando a produtividade e a qualidade dos produtos. Além de disso, robôs colaborativos (cobots) trabalham lado a lado com humanos, compartilhando tarefas e melhorando a ergonomia no ambiente de trabalho.

- **Robôs humanoides**

Os robôs humanoides são máquinas projetadas para se assemelhar, replicar a aparências e os movimentos humanos, sendo utilizados em diversas áreas como educação, saúde, e atendimento ao cliente. Estas máquinas podem caminhar, falar, expressar emoções e interagir com pessoas, o que os torna valiosos em ambientes onde a interação humana é essencial com alunos, e em serviços de atendimento ao cliente para fornecer suporte e informações.

Além disso, estes robôs desempenham papéis importantes na assistência a idosos e pessoas com deficiências, ajudando com tarefas diárias e monitoramento de saúde. Em emergências, robôs humanoides são empregados em simulações para treinar equipes de resgate, operando em ambientes perigosos onde a presença humana seria arriscada. Um exemplo notável é o uso de robôs humanoides em exercícios de simulação de desastres, onde auxiliam na preparação de equipes de resgate para situações realistas. Como exemplos de robôs humanoides temos a Sofia.

A Sophia é um robô altamente avançado e altamente humanoide com uma aparência e comportamento próximos às pessoas. Foi projetada para interagir com seres humanos de maneiras significativas, como ter conversas naturais, responder às perguntas e reconhecer

rostos e expressões faciais. Além disso, tem a capacidade de falar em mais de 20 línguas, identificar o humor humano, lembrar informações e aprender com o comportamento humano (*Machine Learning*). Também pode ler sinais verbais, responder a comandos de voz e usar a inteligência artificial para tomar decisões [3].

A Sophia está equipada com um sistema avançado de visão artificial, composto por câmaras que possibilitam o reconhecimento de objetos e a geração de imagens detalhadas do ambiente. Este robô foi projetado não apenas para interagir com humanos, mas também para auxiliar na resolução de problemas complexos, incluindo na prevenção e tratamento de doenças. Em outubro de 2017, tornou-se o primeiro robô a receber cidadania de um país, a Arábia Saudita. Atualmente, o robô é utilizado em várias áreas, como detecção e prevenção da propagação de doenças infecciosas, melhorar o tratamento de pacientes com transtornos mentais e ajudar na educação de crianças [3].



Figura 3-2 Robô Sophia imitando expressões faciais humanas [70]

- **CyberOne**

O *CyberOne* é um robô humanoide desenvolvido pelo *Xiome Robotics Lab*, direcionado para o entretenimento e para a educação. Equipado com inteligência artificial, reconhecimento de voz, sensores de movimento e de toque, o *CyberOne* possui recursos avançados como reconhecimento facial, de ambiente e interação com utilizadores. Além disso, vem com uma variedade de aplicativos e jogos que permitem aos utilizadores interagir de diversas formas com o robô.

Projetado para ajudar em tarefas domésticas, comerciais e educacionais, o *CyberOne* visa tornar o local de trabalho mais eficiente, seguro e produtivo. o robô pode realizar tarefas como limpar o chão, cozinhar até dar aulas para crianças. Com a capacidade de entender e responder a comandos de voz, reconhecer objetos e se mover com segurança, o *CyberOne* também pode ligar-se à internet para aceder a informações e oferecer suporte às pessoas. A sua habilidade de comunicar com outros robôs e humanos, além de aprender continuamente, destaca o seu potencial para futuras aplicações.



Figura 3-3 O cyberone que promete reconhecer as emoções, anunciado pela xiame [2]

- **Robôs de serviços**

Quando os humanos ensinaram aos computadores as palavras e os símbolos, as máquinas tornaram-se semânticas. Hoje, o mais básico dos computadores sabe ler e escrever, lê tantas páginas quantas aquelas a que acedermos, em qualquer idioma, e faz-nos propostas de produtos ou serviços com base em informação sobre os nossos gostos

Segundo Lacity e Willcocks [40] a aplicação de robôs na linha de produção industrial permitiu automatizar as atividades repetitivas antes realizadas por seres humanos. A interação humano-máquina, permite que o trabalho seja padronizado e ininterrupto, com movimentos precisos e automatização dos movimentos repetitivos e sequenciais que passam a ser executadas por um robô colaborativo, garantindo assim que a operação seja contínua e seu processo com uma melhor qualidade e menores ou nenhum índice de retrabalho pós-processamento no produto acabado.

A Figura 3-4 mostra a contribuição para a ergonomia em atividades de difícil acesso, com potencial de periculosidade e atividades altamente repetitivas, cujo resultado foi a redução no adoecimento dos trabalhadores.



Figura 3-4 Automação no processo produtivo [50]

Os Robôs de serviços são projetados para ajudar em tarefas cotidianas e melhorar a qualidade de vida das pessoas. São amplamente utilizados em setores como hospitalidade, limpeza, segurança e assistência pessoal. Por exemplo, em hotéis, robôs de serviços como o “*Roley*” da Savioke podem realizar o check-in de hóspedes, entregar bagagens e fornecer informações turísticas. Em ambientes domésticos, robôs como o aspirador automático “*Roomba*” da IRobot ajudam na limpeza da casa, proporcionando conveniência e economia de tempo para os utilizadores. Além disso, robôs desempenham papéis importantes na segurança e na monitorização de espaços públicos e privados. Os robôs de vigilância, como o “*Knightscope K5*”, podem patrulhar áreas, detetar intrusos e reportar incidentes em tempo real. Em hospitais, robôs de serviços como o “*TUG*” da *Aethon* auxiliam no transporte de medicamentos e suprimentos, melhorando a eficiência operacional e reduzindo o risco de erros humanos. Um exemplo notável é o uso de robôs de entrega em centros de distribuição, como o “*Starship*” da *Starship technologies*, que agilizam o processo de logística e entrega precisa de produtos.

- **Robôs Médicos**

Os robôs médicos representam uma das aplicações mais inovadoras e impactantes da robótica. São projetados para realizar uma variedade de tarefas no campo da medicina, incluindo cirurgias precisas, diagnósticos avançados e cuidados com pacientes. A tecnologia robótica permite que esses robôs executem procedimentos com um nível de precisão que muitas vezes superam as habilidades humanas. Isso se traduz em menos erros, recuperações mais rápidas e procedimentos menos invasivos para os pacientes. A Figura 3-5 ilustra de forma exemplar um robô cirúrgico em operação.




Figura 3-5 Robô cirúrgico usado em ambientes hospitalares [50]

Os robôs cirúrgicos, como o famoso da Vinci, que é ilustrado na Figura 3-6, são controlados por cirurgiões altamente treinados e são utilizados para realizar procedimentos complexos através de pequenas incisões. Estes robôs fornecem uma visualização tridimensional e uma precisão de movimento que reduz o risco de complicações. Além disso, os robôs são usados em procedimentos de reabilitação, onde auxiliam pacientes na recuperação de movimentos e funções após lesões ou cirurgias.



Figura 3-6 Robô de reabilitação e cirúrgico, Vinci [25]

Outro tipo de robô usados na medicina que tem apresentado uma grande importância são aqueles usados na telemedicina, onde estes permitem que os médicos examinem e tratam pacientes em locais remotos, eliminando assim as barreiras geográficas e oferecem cuidados médicos nas áreas de difícil acesso.




Figura 3-7 Robô de telemedicina [29]

Tal como estes, existem robôs de assistência na área de diagnósticos. Robôs equipados com inteligência artificial que podem analisar grandes volumes de dados médicos, identificação de padrões e fornecendo diagnósticos precisos em menos tempos em relação aos métodos tradicionais, os mesmos são utilizados para exames de imagem, análises laboratoriais e em outros casos são usados nas triagens de pacientes.

### 3.2 Fundamentos de lógica fuzzy

Os princípios da lógica *fuzzy* foram inicialmente desenvolvidos por Jon Lukasiewicz, que introduziu a ideia de conjuntos com grau de pertinência em 1920. Lukasiewicz, que viveu entre 1878 e 1956, baseou suas ideias na lógica clássica de Aristóteles, estabelecendo uma fundação teórica que influencia posteriormente o campo da lógica *fuzzy*. Na década de 1960, Lofti Asker Zadeh, professor de ciências da computação da Universidade da Califórnia, desenvolveu e publicou o conceito da lógica *fuzzy*, formalizando-a como um campo de destino de estudo [40].

Zadeh observou que muitas regras e avaliações de cotidiano não podiam ser explicadas de forma precisa usando a lógica tradicional, que é binária e aceita apenas valores de verdadeiro ou falso. Ele introduziu a lógica *fuzzy*, que permite valores de pertinência intermediários entre 0 e 1, oferecendo uma maneira mais flexível e natural de lidar com incertezas e nuances. Este conceito, também explorado por Max Black em 1937 com a definição de conjunto *fuzzy* e operações associadas, foi formalmente publicado por Zadeh em 1965 com seu artigo “*Fuzzy Sets*” [53].

Existe uma diferenciação entre a lógica convencional e a lógica *fuzzy*, a lógica convencional trata elementos como pertencentes ou não a um conjunto, de forma binária. Por exemplo, a altura de uma pessoa é classificada rigidamente como baixo, médio e alto. Em contraste, a lógica *fuzzy* permite que um elemento tenha um grau de pertinência em múltiplos conjuntos, refletindo *nuances* e variedades, como uma altura que pode ser parcialmente média e alta ao mesmo tempo. Para ilustrar, observa a Figura 3-8, que representa um exemplo típico da teoria clássica, apresentando a altura de uma pessoa através de três conjuntos: baixo, médio e alto. Nesse exemplo, dado um elemento  $x$  qualquer, o mesmo pertencerá a um dos conjuntos do gráfico. Por exemplo, se  $x = 1,65$ , então  $x$  pertence ao conjunto médio e não aos demais, ou seja, um elemento pertence ou não a um determinado conjunto e, além disso, tal elemento não pertence a mais de um conjunto [32].




Figura 3-8 Representação na forma de conjuntos da altura de uma pessoa, sob o ponto de vista da Lógica convencional (à esquerda) e do da Lógica Fuzzy (à direita) [62]

Ao contrário da lógica convencional, a lógica *fuzzy* utiliza a ideia de que todas as coisas (temperatura, altura, velocidade, etc.) admitem graus de pertinência. Com isso, a lógica *fuzzy* tenta modelar o senso de palavras, tomada de decisão ou senso comum do ser humano.

A lógica *fuzzy* é conceitualmente fácil de entender, tem uma ampla flexibilidade e está baseada em uma linguagem natural, em vez de números, para expressar valores verdadeiros. Esses valores são apresentados linguisticamente, como, ausente, presente, instável, moderadamente, estável, muito vulnerável, vulnerável, não vulnerável, entre outros. A lógica *fuzzy* apresenta algumas características, incluindo o uso de modificadores de predicado como muito, não, pouco, bastante e médio; um amplo conjunto de quantificadores como poucos, vários, em torno de, usualmente; o uso das probabilidades linguísticas, como provável, improvável, que são interpretados como números nebulosos e manipulados pela sua aritmética, manuseia todos os valores entre 0 e 1 [16].

Silva et al. [62] elaboraram um projeto cujo objetivo foi propor um instrumento baseado em lógica *fuzzy* capaz de padronizar a inspeção e gerar indicadores de controlo sanitário. O modelo foi desenvolvido com 18 subsistemas, que resultaram da aglutinação de elementos identificados na inspeção, como aqueles que interferem na avaliação e permitiam todas as etapas do GRSS (Gestão de resíduos de segurança de saúde). A validação do modelo foi realizada em dez unidades de saúde no Rio de Janeiro, Brasil, de maio a novembro de 2009. Os resultados obtidos no sistema seguiram os diagnósticos realizados pelos especialistas, mostrando a possibilidade de sistematização e racionalização das avaliações de RP (ricas potências). O estudo demonstrou sucesso realçando assim a importância da aplicação das lógicas *fuzzy* para solucionar problemas de saúde.

### **3.3 Fundamento dos algoritmos genéticos**

Historicamente, algoritmos genéticos (AGs) são algoritmos de otimização e de procura inspirados na evolução natural, desenvolvidos por John Holland na década de 1960. A ideia baseia-se na teoria da seleção natural de Charles R. Darwin, onde indivíduos com maior aptidão têm maior probabilidade de sobrevivência e reprodução. Holland propõe a simulação matemática deste processo evolutivo, utilizando operadores genéticos como crossover e mutação.

Os primeiros estudos e aplicações dos AGs foram desenvolvidos por investigadores como Bagley, Rosenberg, Cavicchio, e Hollstien, abordando desde jogos até otimização de funções matemáticas. A popularização dos AGs ocorreu com a publicação “*Adaptation in Natural and Artificial Systems*” de Holland em 1975 e foi amplamente disseminada pelo trabalho de seu aluno David Goldberg, autor de “Algoritmos Genéticos em Busca, Otimização e Aprendizado de Máquina” [46].

Os AGs codificam soluções de potências em cromossomos, aplicando operações de mutação e de cruzamento para preservar informações críticas. Ao longo dos anos, variações dos AGs surgiram com diferentes representações e operadores, sendo aplicados em diversas áreas científicas devido á sua versatilidade e eficiência [52]. A evolução e a melhoria dos sistemas computacionais também contribuíram significativamente para o desenvolvimento e a aplicação dos AGs.

Algoritmos genéticos (AGs) são algoritmos de otimização que utilizam um mecanismo probabilístico de busca das soluções, inspirados na evolução biológica. Conforme Bento e Kagan (2008), eles combinam aspectos da genética e da seleção natural dos indivíduos. Apesar de usarem procedimentos aleatórios, os AGs se diferenciam dos métodos de procura puramente aleatórios. Goldberg [19], destaca que os AGs trabalham com a codificação dos parâmetros do problema em vez dos próprios parâmetros, procuram soluções ótimas a partir de um conjunto de soluções, usam uma função de avaliação para as soluções codificadas em *strings* (conjunto de bits em série), geralmente em binário, e aplicam regras probabilísticas na procura de novas soluções de elevada qualidade [18].

A estrutura básica de um algoritmo genético (AG) envolve a codificação de cromossomos, que pode variar de acordo com o problema, utilizando *strings* de bits ou variáveis numéricas contínuas. Estes cromossomos são avaliados por uma função de avaliação, que mede o seu desempenho na resolução do problema, através de três técnicas principais: seleção, cruzamentos e mutação. Estes mecanismos são cruciais para a evolução da população (conjunto de indivíduos) e estão interligados no modelo básico de um AG [38].

A representação ou codificação dos cromossomos é crucial nos algoritmos genéticos (AGs), pois define como os indivíduos são representados e impacta diretamente na solução do problema. Existem três abordagens principais para codificação: a codificação binária, que utiliza um conjunto de bits em série (*string*); a codificação real, que usa apenas valores inteiros e é menos comum. A função avaliação avalia a capacidade dos cromossomos para resolver o problema, determinando a sua capacidade de reprodução com base no desempenho obtido [12].

A codificação binária, embora simples, pode ser ineficiente devido à necessidade de utilizar *strings* longas que aumentam o esforço computacional e o tempo de convergência. Para superar estas limitações, surgiu a codificação real, que oferece maior eficiência ao representar cromossomos com valores reais. Desta abordagem permite uma procura mais ampla e evita problemas de convergência prematura.

Os Algoritmos Genéticos (AGs) apresentam vantagens como a robustez, flexibilidade e aplicação a uma ampla gama de problemas, especialmente os multimodais e complexos.

São eficazes em evitar ótimos locais, não dependem de informações de derivadas ou gradientes, e são relativamente fáceis de implementar. No entanto, a codificação binária pode ser problemática em problemas de alta dimensionalidade [15].

No entanto, os AGs também apresentam desvantagens. A procura pelo ótimo global pode ser difícil e frequentemente requer um grande número de avaliações da função de avaliação, o que pode ser computacionalmente intensivo. Além disso, a diversidade de configurações possíveis pode complicar a resolução dos problemas [42].

Na área da saúde, os AGs têm várias aplicações, como otimização de tratamentos e planeamento cirúrgico, seleção de características para diagnóstico e previsão de surdos. Também são usados no desenho de fármacos, otimização de planeamento de equipa e análise de imagens médicas. Estas aplicações mostram a versatilidade dos AGs em resolver problemas complexos e melhorar a eficiência dos serviços de saúde.

### **3.4 Breve história e evolução das redes neuronais**

O desenvolvimento das redes neuronais remonta a 1943, quando McCulloch e Pitts publicaram o primeiro estudo descrevendo-as, combinando neurofisiologia e lógica matemática. Em 1949, Hebb introduziu a ideia de modificação da sinapse conforme a aprendizagem, estabelecendo uma regra que liga a atividade neuronal à eficiência sináptica. Rosenblatt, em 1958, propôs o *Perceptron*, o primeiro modelo artificial de um neurónio artificial capaz de classificar padrões linearmente separáveis. Em 1960, Widrow e Hoff conceberam o algoritmo *Least Mean Squares* (LMS). Além disso, em 1962, apresentou a Madaline, uma das primeiras redes neuronais em camadas. Em 1969, Minsky e Papert criticaram o *Perceptron*, o que interrompeu temporariamente a pesquisa em redes neuronais artificiais.

No entanto, em 1982, Hopfield e Kohonen reacenderam o interesse, apresentando modelos como a rede de Hopfield e os mapas auto-organizáveis. Na década de 80, ressurgiram as redes baseadas em perceptron de múltiplas camadas, utilizando o algoritmo *backpropagation*, resolvendo problemas anteriormente levantados por Minsky e Papert. Rumelhart em 1986, desenvolveu o algoritmo *backpropagation* (de retro propagação), que se tornou o mais conhecido e utilizado para o treino de redes neuronais artificiais. O livro "*Parallel Distributed Processing*", de Rumelhart e McClelland, também influenciou o uso generalizado do algoritmo *backpropagation*. Embora o algoritmo tenha sido proposto por diferentes investigadores, é creditado a Rumelhart por sua ampla aplicação e compreensão [28].

Ao longo dos anos, outros investigadores contribuíram para o desenvolvimento e aplicação do algoritmo de *backpropagation*, como Werbos em 1974 e Parker e LeCun em 1985. No entanto,

Rumelhart foi fundamental para a compreensão e utilização prática do algoritmo, impulsionando significativamente o avanço das pesquisas em redes neuronais artificiais.

A Tabela 3.1 ilustra uma breve evolução das RNAs, desde a sua criação até os tempos atuais, tal como os investigadores que contribuíram nesta grande evolução. A mesma, serve para mostrar de maneira resumida como diversas pesquisas foram feitas e estão a ser feita para tornar as redes neuronais artificiais cada vez mais sofisticadas, ajudando assim na resolução de diferentes problemas e áreas. É notável que, desde os primeiros modelos de McCulloch e Pitts até os modernos modelos de deep learning e *transformers*, as RNAs evoluíram significativamente. Inicialmente, eram conceitos teóricos, mas com o tempo se transformaram em ferramentas práticas, impactando diversas indústrias e áreas de pesquisa, especificamente na saúde.

Tabela 3-1 Desenvolvimento/marco histórico sobre redes neuronais artificiais e pesquisadores envolvidos

Período	Desenvolvimento / Marco histórico	Modelo	Pesquisadores
1943	Proposta do primeiro modelo matemático de neurónio biológico.	Neurónio MCP (McCulloch-Pitts)	Warren McCulloch e Walter Pitts
1958	Introdução da topologia de rede chamada perceptron.	Perceptrons de Múltiplas Camadas (MLP)	Frank Rosenblatt
1969	Publicação destacando as limitações dos perceptrons.	Análise crítica do MLP	Marvin Minsky e Seymour Papert.
1982	Renascimento do interesse por RNAs com redes recorrentes.	Modelo de Hopfield	John Hopfield
1980	Popularização do algoritmo de retropropagação.	Retropropagação em MLP.	David E. Rumelhart, Geoffrey E. Hinton e Ronald J. Williams
1990-2000	Expansão e aplicação prática em reconhecimento de voz e imagem.	Redes Neuronais Convolucionais (CNNs) e Redes Neuronais Recorrentes (RNNs).	Yann LeCun (CNNs), Jürgen Schmidhuber e Sepp Hochreiter (LSTM).
2010	Avanço significativo em técnicas de deep learning.	Redes Neuronais Profundas (DNNs)	Geoffrey Hinton, Yann LeCun, Yoshua Bengio
Anos 2020	Avanços em IA generativa e aprendizagem por reforço.	Redes Generativas Adversariais (GANs), Transformers.	Ian Goodfellow (GANs), Ashish Vaswani e colegas (Transformers).



o comportamento das sinapses, os terminais de entrada do neurónio artificial possuem pesos. Em termos matemáticos, podemos descrever um neurónio escrevendo o seguinte par de equações 3.1 e 3.2 [36].

$$Y_1 = \sum_{j=i}^n (W_n * X_1 + b) \quad (3.1)$$

$$Y_1 = f(W_1 X_1 + W_2 X_2 + W_n X_n + b) \quad (3.2)$$

Em que  $X_1, X_2, \dots, X_n$  são os sinais de entradas,  $W_1, W_2, \dots, W_n$  são os pesos sinápticos do neurónio 1,  $b$  é o bias,  $f$  é a função de ativação,  $Y_1$  é o sinal de saída do neurónio. Uma descrição do modelo artificial de um neurónio está ilustrada na Figura 3-10.

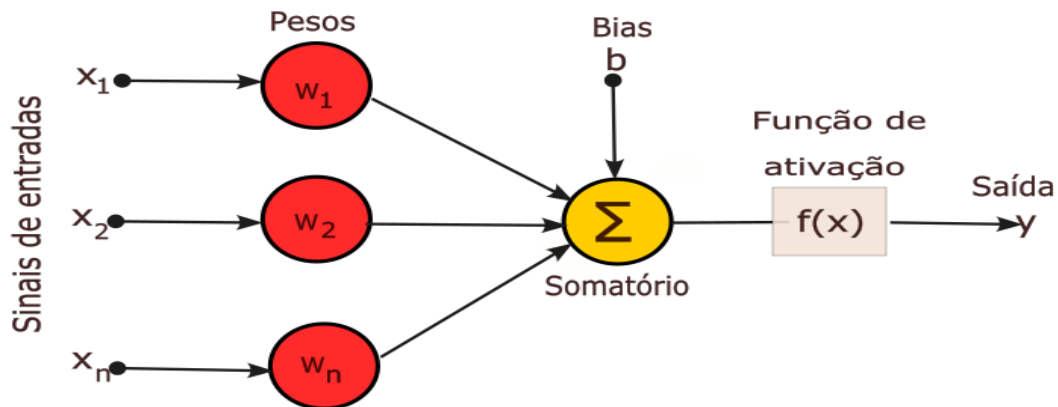


Figura 3-10 - Modelo de um neurónio artificial

### 3.4.3 Principais aplicações e casos de uso de redes neuronais

As redes neuronais artificiais, inspiradas no funcionamento do cérebro humano, tornaram-se uma ferramenta poderosa em diversos campos da ciência e da tecnologia. A sua capacidade de aprender a partir de dados e realizar tarefas complexas tem levado a avanços significativos em áreas como visão computacional, processamento de linguagem natural, análise de dados, controle e automação, entre outros ramos de conhecimentos.

A utilização da RNA para um fim específico tem relação direta com a eficiência com que esta fornece respostas próximas aos dados de saída reais. Para isso, o neurónio artificial deve ser capaz de aprender uma determinada tarefa [60].

Neste contexto, é fundamental compreender as principais aplicações e casos de uso das redes neuronais, destacando como elas estão sendo utilizadas para resolver problemas do mundo real e impulsionar a inovação em diferentes setores. Nos parágrafos seguintes, são enumerados alguns trabalhos de pesquisas relacionados as aplicações mais relevantes das redes neuronais e como elas estão transformando diversas áreas do conhecimento.

Rosas *et al.* [55] utilizaram redes neurais artificiais em uma metodologia aplicada à alocação de recursos na área da saúde, com o objetivo principal de descrever a construção de um fator de alocação de recursos financeiros com base nas necessidades de saúde da população. O estudo adotou uma abordagem quantitativa, utilizando dados recolhidos em fontes de domínio público, referentes ao estado de Pernambuco entre os anos de 2000 e 2010. Foram selecionadas variáveis que refletissem indicadores epidemiológicos, demográficos, socioeconômicos e educacionais, a fim de compor um fator de alocação que identificasse as necessidades de saúde da população. O estudo demonstrou sucesso nesta abordagem.

Segundo Vieira *et al.* [68], foi desenvolvido um sistema para auxílio ao diagnóstico de diabetes, utilizando redes neurais artificiais (RNAs). Este artigo aborda o desenvolvimento de um sistema cuja principal função é auxiliar os profissionais da área da saúde no diagnóstico da diabetes, aproveitando a capacidade de aprendizagem das RNAs. Foram empregues duas RNAs, cujo treino foi realizado utilizando a base de dados Pima Indians. Esta base de dados contém informações referentes a uma comunidade indígena conhecida por apresentar a maior taxa de incidência de diabetes no mundo. As RNAs possuem objetivos diferentes, sendo que uma foi treinada para identificar casos normais e a outra para diagnosticar casos de diabetes [67].

Júnior *et al.* [37] apresentaram um estudo sobre redes neurais recorrentes, demonstrando sua aplicabilidade na análise do movimento humano e na área da saúde. Pode-se afirmar que um dos tipos de redes neurais artificiais (RNA) mais amplamente utilizados para análise de imagens são as redes neurais recorrentes (RNR).

Fonseca *et al.* [16], propôs um método de baixo custo computacional e alta eficiência para auxiliar no diagnóstico da tuberculose. Utilizando imagens de radiografia torácicas para a construção de um modelo de rede neuronal artificial com recursos BPPC (Boas práticas de processamento computacional) com e sem a geração de dados sintéticos. Os resultados equivalentes à literatura relacionada mostraram o desempenho excepcional e de baixo custo da solução, colocando-a como uma solução alternativa viável.

Entre esses estudos onde se aplicaram RNAs, pode-se encontrar vários estudos e os mesmos demonstraram grande êxito na resolução de problemas. Assim sendo, é seguro dizer que as redes neurais artificiais estão transformando a área da saúde com aplicações que vão desde o diagnóstico até a pesquisa e desenvolvimento de novos tratamentos. No diagnóstico de doenças, analisam imagens médicas e detetam anomalias com alta precisão, frequentemente superando a capacidade humana. Além disso, estas redes preveem a progressão de doenças crônicas e complicações clínicas, auxiliando na tomada de decisões médicas. Na medicina personalizada, as RNAs ajudam a desenvolver tratamentos individualizados e na análise de

como pacientes respondem a medicamentos, garantindo terapias mais eficazes e com menos efeitos colaterais.

Os mesmos, aceleram a descoberta de novos medicamentos ao modelar interações moleculares e analisar dados de ensaios clínicos. Dispositivos vestíveis equipados com RNAs monitoram a saúde em tempo real, detetando problemas como arritmias cardíacas e alertando utilizadores e profissionais de saúde. Estas inovações estão tornando os cuidados de saúde mais eficientes, personalizados e acessíveis, melhorando significativamente a precisão de diagnósticos, tratamento dos pacientes e prevenção de doenças.

### **3.4.4 Arquiteturas e Topologias**

As arquiteturas e topologias das RNAs são projetadas de maneira a acomodar diferentes tipos de dados e resolver diversos problemas. Cada arquitetura possui suas próprias características e é adequada para diferentes tipos de tarefas. Nesta dissertação, que tem como foco principal usar a rede neuronal para prever o risco da diabetes na população da Covilhã, vamos explorar uma das arquiteturas e topologias mais comuns em redes neuronais e entender como ela é aplicada em diferentes contextos da aprendizagem máquina e inteligência artificial. Em geral, podemos identificar diversas classes de arquiteturas de RNAs, entre elas menciona-se as redes neuronais recorrentes, redes neuronais convencionais, redes neuronais de memória curta e longa, redes neuronais generativas adversarias, redes neuronais *feedforward*, entre outras. Portanto, para esta dissertação focalizamos simplesmente nas redes neuronais *feedforward* ou também conhecidas como redes não recorrentes ou de propagação para a frente.

### **3.4.5 Redes neuronais Feedforward: estrutura e funcionamento**

As redes *feedforward* constituem a base de muitos modelos de redes neuronais artificiais (RNAs) desenvolvidos ao longo dos anos. De acordo com Kriesel [58], o funcionamento de uma rede *feedforward* envolve o cálculo da saída para qualquer entrada, passando o sinal apenas uma vez, da camada de entrada até a camada de saída. Isso significa que cada neurónio em uma camada está diretamente conectado apenas aos neurónios da próxima camada.

Para que uma RNA seja capaz de fazer inferências sobre os dados é essencial que ela seja treinada. Segundo Haykin [36], o processo de aprendizagem de uma RNA envolve a adaptação contínua dos parâmetros da rede através da interação com o ambiente. Esse processo pode ser classificado em dois tipos principais:

A aprendizagem supervisionada é caracterizada como sendo um tipo de treino em que um conjunto de dados de entrada é apresentado à rede junto com um conjunto correspondente de saídas esperadas. O algoritmo de aprendizagem ajusta os pesos das conexões entre os

neurónios para que, dada uma entrada, a rede produza uma saída o mais próxima possível da saída desejada.

A aprendizagem não supervisionada é caracterizada de forma em que as informações de entrada são utilizadas para o treino. A aprendizagem ocorre por meio da identificação de padrões e agrupamentos nos dados, sem a necessidade de saídas esperadas. Esse tipo de aprendizagem é comumente utilizado na identificação de estruturas desconhecidas nos dados.

Na Figura 3-11 está ilustrada a representação de uma arquitetura denominada por rede neuronal artificial *feedforward*, também conhecida como propagação para frente, constituída por três entradas, duas camadas escondidas com três neurónios em cada camada escondida, e, por fim, uma saída. É uma arquitetura bastante conhecida e uma das mais usadas.




Figura 3-11 - Rede neuronal típico de uma arquitetura *feedforward*

Lembrando que, em todas as redes neuronais tem o valor bias subentendido ou visível, que podemos conceituar como um parâmetro adicional em cada neurónio, exceto na camada de entrada.

O bias é um parâmetro da rede neuronal que é inserido junto às entradas. É tratado como uma entrada e também possui um peso, que pode ser atualizado pelo algoritmo de treino. Bias, na sua tradução literal, significa “viés” ou “preconceito”, trata-se de uma forma de direcionar a aprendizagem da rede neuronal e também impedir que ela transmita valores nulos por acidente, fazendo com que a rede neuronal caia em mínimos locais e não consiga aprender corretamente [26].

### 3.4.6 Funções de Ativação

A função de ativação representa o efeito que a entrada interna e o estado atual de ativação exercem na definição do próximo estado de ativação da unidade [26]

Em relação à tipologia, podemos afirmar que existem vários tipos de funções de ativação. Para esta dissertação, serão mencionadas algumas que poderemos utilizar para resolver nosso problema de estudo, incluindo a função de ativação degrau, ReLU, sigmoide, linear e tangente hiperbólica. Abaixo, segue uma breve descrição de cada uma delas.

Função Sigmoide: Esta função, representada pela equação (3.3), com o comportamento gráfico ilustrado na Figura 3-12, pode assumir valores entre 0 e 1.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3.3)$$



Figura 3-12 - Função de ativação Sigmoide

Função Tangente Hiperbólica (TanH): Esta função, representada pela equação (3.4), com o comportamento gráfico representado na Figura 3-13, pode assumir valores entre -1 e 1.

$$\tanh(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (3.4)$$

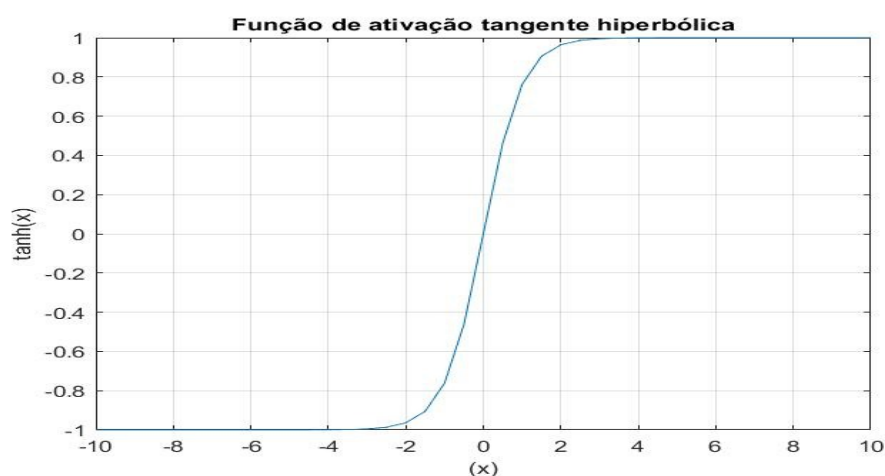


Figura 3-13 - Tangente Hiperbólica (TanH).

ReLU (Unidade Linear Retificada): Ativação linear para valores positivos, zero para valores negativos. Amplamente utilizada em redes densas (com muitos neurónios). Esta função é representada pela equação (3.5) e o seu comportamento gráfico é apresentado pela Figura 3-14

$$f(x) = \max(0, x) \quad (3.5)$$

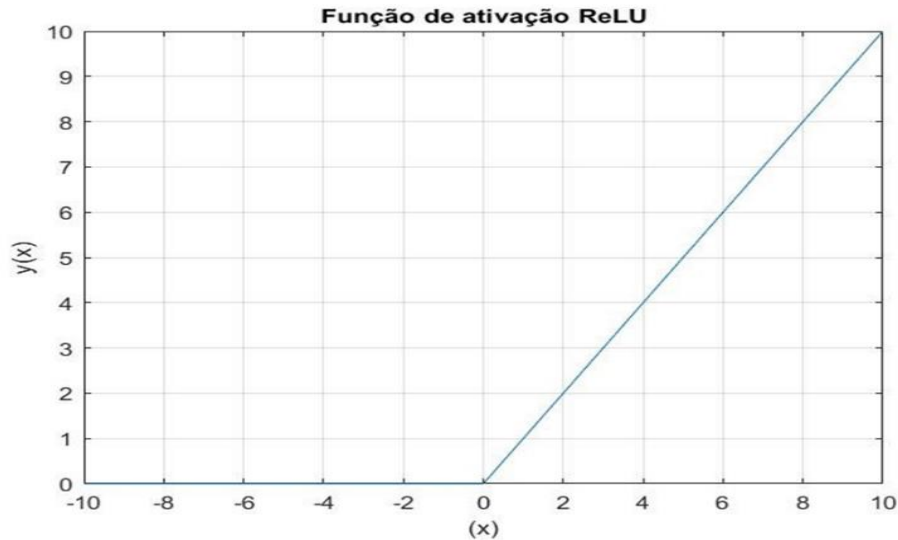


Figura 3-14 - ReLU (Unidade Linear Retificada)

Função linear é uma função matemática que representa uma relação direta entre duas variáveis, onde a saída é uma combinação linear da entrada, conforme mostra a Figura 3-15 e sendo representada pela equação (3.6).

$$f = ax + b \quad (3.6)$$



Figura 3-15 - Função de ativação linear

Degrau (Step): Produz uma saída binária (0 ou 1) dependendo se o input ultrapassar ou igualar o limiar. Utilizada em redes neuronais de caracter simples, mas raramente em camadas escondidas de redes neuronais artificiais densas. A função é representada pela equação 3.8 e ilustrada na Figura 3-16

$$f(x) = 1, x \geq 0 \text{ ou } f(x) = 0, < 0 \quad (3.7)$$



Figura 3-16 - Função de ativação Degrau

### 3.4.7 Conjuntos de treino, teste e validação em ambiente de aprendizagem máquina

A metodologia de treino, teste e avaliação de desempenho é essencial no desenvolvimento de redes neuronais artificiais e em qualquer aprendizagem de máquinas. Este processo envolve a preparação dos dados, definição de métricas de desempenho, validação dos modelos e otimização de hiperparâmetros (parâmetros livres). É fundamental para garantir a precisão e confiabilidade da RNA.

A aprendizagem de uma rede neuronal artificial é um processo onde os parâmetros livres são adaptados através de um processo de estimulação pelo ambiente em que a rede está inserida. Com isso, o tipo de aprendizagem é determinado com base na maneira pela qual a modificação dos parâmetros ocorre. Em síntese, tem-se a seguinte sequência de eventos: a) a rede neuronal é estimulada por um ambiente; b) a rede neuronal sofre modificações nos seus parâmetros livres como resultado desta estimulação; c) a rede neuronal responde de uma maneira nova ao ambiente, devido às modificações ocorridas na sua estrutura interna [36].

A aprendizagem de uma RNA é realizada por meio de processos iterativos de ajustes aplicados aos pesos sinápticos, o chamado treino. A aprendizagem só ocorre quando a rede neuronal atinge uma solução generalizada para um determinado problema. Em síntese, treinar uma rede neuronal é ajustar a sua matriz de pesos sinápticos (parâmetros livres) de forma que o vetor de saída coincida com um valor desejado para cada vetor de entrada [51].

Portanto, na etapa de treino, os pesos sinápticos variam até que se ajustem ao objetivo esperado. Tal processo pode ser conduzido de diversas maneiras, sendo que atualmente há vários métodos para a inicialização dos pesos e, também, para o cálculo e propagação do erro de correção dos mesmos [31]

Existem diversos algoritmos de treino, na Tabela 3-2 são apresentados de modo não exaustivo os nomes de alguns dos algoritmos existentes.

Tabela 3-2 Algoritmos de treinamentos de uma RNA no MATLAB

<b>Tag</b>	<b>Algoritmo</b>
<i>Traingd</i>	<i>Gradient descent backpropagation</i>
<i>Traingda</i>	<i>Gradient descent with adaptive e learning rate backpropagation</i>
<i>Traingdm</i>	<i>Gradient descent with momentum backpropagation</i>
<i>Traingdx</i>	<i>Gradient descent with momentum and adaptive e learning rate backpropagation</i>
<i>Trainln</i>	<i>Levenberg- Marquardt blackpropagation</i>

Ao realizar um treino, é comum e importante definir e treinar também o número de épocas (ou iterações), o valor máximo para determinar o critério de paragem e a forma como os dados serão divididos, como por exemplo, em conjuntos de treino, validação e teste. São demonstrados uma possível distribuição de dados respetivamente, dados de treino 70% dados de teste 15% e por fim, dados de validação 15%.

É notório na distribuição acima que o valor maior é do treino e podemos anular o valor do teste quando este é feito separadamente. É obrigatório que o somatório do valor de treino, teste e validação seja equivalente a 100% dos dados disponíveis.

Por outro lado, é necessário normalizar as entradas e as saídas ao criar uma rede neuronal, isto nos ajuda a melhorar a estabilidade do treino, acelerar a convergência, reduzir a bias, melhorar a generalização e reduzir o risco de *overfitting*. Como exemplo, se tivermos uma rede neuronal com três entradas com valores diferentes, ao normalizar estas entradas, ajustamos de maneira que não haja uma maior concentração na entrada com o maior valor. E assim também acontece nas saídas.

### 3.5 Outras técnicas da inteligência artificial

Nesta secção mencionou-se outras técnicas artificiais que contribuem para as máquinas desempenharem funções humanas. A inteligência artificial (IA) é uma área vasta que abrange diversas subáreas além das redes neuronais, sistemas de *fuzzy* e algoritmos genéticos. Estes outros tópicos também desempenham um papel relevante em áreas como a saúde, melhorando o diagnóstico, o tratamento e a gestão de dados. A seguir, discutem-se alguns dos outros tópicos de IA aplicados à saúde.

A aprendizagem de máquinas, designada em inglês como *machine learning*, envolve algoritmos que aprendem a partir de dados e fazem previsões ou decisões sem serem explicitamente programados pela tal. Na saúde, é amplamente utilizada na previsão de doenças e na personalização de tratamentos com base em históricos de pacientes e dados genéticos [57].

Representação do conhecimento, é um fator que se refere à forma como a informação é modelada de forma compreensível por sistemas computacionais. Em saúde pode ser aplicada na criação de sistemas de apoio para a decisão clínica onde as ontologias medicinais permitem representar e relacionar sobre doenças e tratamentos de forma eficiente [10].

A interface entre homem e máquina é parte da inteligência artificial que tem a interação entre os humanos e as máquinas. É essencial especificamente em contextos médicos, onde os sistemas de IA podem auxiliar profissionais de saúde. A interface de voz, como assistente virtuais, já são usadas em hospitais para aceder rapidamente a informações sobre pacientes ou auxiliares em cirurgia complexas [57].

A Mineração de Dados, designado em inglês *data mining*, é um processo de extrair padrões relevantes de grandes volumes de dados. Na área da saúde, é fundamental para a análise de registos em doenças, respostas a tratamentos e grupos de risco [41]

Visão computacional, esta área foca-se em permitir que máquinas vejam e interpretem imagens. Na saúde, a visão computacional é usada no diagnóstico por imagem, como a identificação de tumores em mamografias ou a deteção de doenças pulmonares em radiografias torácicas [66].

Inteligência de Exame, inspirada no comportamento de grupos de animais, como enxames de abelhas ou colónias de formigas, a inteligência de enxame é usada para resolver problemas complexos. Em saúde, pode ser aplicada na otimização de rotas para entrega de medicamentos de tratamentos com base em planificação de tratamentos com base em múltiplos critérios, segundo [57].

Processamento de Linguagem Natural (PLN), este processo permite que sistemas de IA compreendem e processem linguagem humana. Em saúde, pode ser utilizado para analisar notas clínicas, automatizar diagnósticos através de registos médicos e fornecer respostas automáticas a pacientes em plataformas de telemedicina [48].

Inteligência coletiva, envolve a combinação de conhecimentos e competências de várias fontes para criar uma inteligência superior. Na saúde, é aplicada na investigação colaborativa e em plataformas de saúde pública que agregam dados de múltiplas fontes para melhorar a vigência de doenças e a resposta a pandemias [48].

Colónia artificial de formigas e abelhas, é inspirada pelo comportamento naturais destes insetos, estas colónias são utilizadas em IA para resolver problemas de otimização. Em saúde podem ser aplicadas na otimização da gestão de recursos hospitalares, como o agendamento

## Capítulo 4

Neste capítulo é descrita a metodologia para o desenvolvimento desta dissertação, que se foca na criação da rede neuronal artificial para prever os riscos de diabetes na população da Covilhã, com base em fatores multidimensionais. Primeiramente, é feita uma apresentação, posteriormente é enunciado um pequeno resumo sobre a ferramenta utilizada, aquisição de dados, estatística, processamento dos dados e, por fim, o desenvolvimento da rede neuronal.

### Materiais e Métodos

#### 4.1 Apresentação

A metodologia utilizada nesta pesquisa é transversal, quantitativa e analítica, seguida de uma revisão abrangente da literatura para compreender o estado atual da integração de máquinas agindo como humanos na área da saúde em base de dados, especificamente focada na criação de uma rede neuronal para prever o risco de diabetes na população da Covilhã, com bases em fatores multidimensionais.

As informações foram recolhidas nas plataformas Pub MED, Google Acadêmico e *Science Direct*. Os métodos de revisão foram estabelecidos antes do início da pesquisa. Os artigos selecionados contêm em seus títulos, *abstract* ou palavras-chave os termos: redes neuronais, computação, aprendizagem de máquinas, máquinas e humanos, diabetes, inteligência artificial. Utilizou-se como critério de exclusão todos os artigos que descreviam temas distintos ao abordado e aqueles que falavam de temas relacionados, porém foram elaborados no período anterior a 1999, com o objetivo de ter conteúdo atualizado neste projeto, além de outros artigos que não continham referências e citações. O critério de inclusão englobou todos os artigos que abordavam temas semelhantes e relacionados ao abordado e que foram elaborados no período posterior a 2000, com o objetivo de ter conteúdo atualizado neste projeto, além de outros artigos que continham referências e citações. Apesar de nossa pesquisa ter sido realizada em língua portuguesa, os artigos de apoio encontrados em espanhol, inglês ou em outra língua também foram considerados no processo de seleção desta revisão sistemática.

#### 4.2 Ferramenta utilizada

Para o desenvolvimento da rede neuronal foi utilizado o *software* MATLAB (*Laboratory Matrices*). Trata-se de uma ferramenta amplamente utilizada no campo da inteligência artificial (IA), proporcionando diversas funcionalidades que facilitam o desenvolvimento, implementação e análise de algoritmos de IA.

O *software MATLAB (Laboratory Matrices)*, desenvolvido pela *The MathWorks*, é um sistema interativo baseado em uma linguagem de programação matricial, onde as soluções e problemas são expressos em linguagem matemática. Através do *software MATLAB* é possível realizar análise numérica, operações com matrizes, criação de gráficos e interfaces com o utilizador [49]. É amplamente utilizado em diversas áreas, incluindo engenharia, matemática, física, biologia computacional, finanças e muito mais.

Uma das principais razões para a popularidade do *MATLAB* é sua linguagem de programação própria, que é projetada especificamente para cálculos numéricos e análises complexas. A sintaxe do *MATLAB* é relativamente fácil de aprender e permite aos utilizadores realizar uma ampla gama de operações matriciais e vetorizadas de forma eficiente.

Além disso, o *MATLAB* possui uma extensa biblioteca de funções integradas para realizar tarefas comuns, como manipulação de dados, visualização de dados, otimização, processamento de sinais e imagens, modelagem e simulação de sistemas dinâmicos, entre outras.

### **4.3 Aquisição de dados e amostra selecionada**

Para esta dissertação, recolheu-se os dados por meio de um questionário direcionado à população de Covilhã, com foco na investigação do risco de diabetes. O objetivo é desenvolver uma rede neuronal artificial que integre uma variedade de fatores multidimensionais, como histórico familiar, estilo de vida, condições médicas prévias e características genéticas, para prever o risco de diabetes em indivíduos da comunidade em estudo, exemplificando de como as máquinas podem agir de maneira semelhante aos humanos. O questionário elaborado foi constituído por 22 perguntas, formuladas com a ajuda de um médico e da revisão sistemática.

### **4.4 Pré-processamento dos dados colhidos**

Esta etapa tem impacto significativo para o desempenho da rede neuronal, podendo melhorar a capacidade de generalização da mesma. As bases de dados podem ser carregadas de atributos sem que estes estejam relacionados ao objetivo real do modelo proposto. Portanto, é necessário remover o máximo de informações irrelevantes e redundantes. Lidar com dados em falta e realizar a normalização dos atributos também são tarefas realizadas durante a etapa de pré-processamento [4].

O pré-processamento dos dados constitui uma etapa crucial na análise de conjuntos de dados, especialmente em pesquisas sobre diabetes, onde a complexidade dos dados é significativa. Durante esta fase, foram implementadas ações voltadas à seleção dos dados, com objetivo de identificar e corrigir quaisquer valores ausentes, inconsistentes ou até mesmo inválidos que possam comprometer a integridade da rede neuronal artificial.

Posteramente, foi realizada a codificação de variáveis categóricas, uma vez que o questionário empregado inclui perguntas com respostas categorizadas, como sexo (masculino/feminino) e nível de atividade física (baixo/médio/alto). Destas variáveis foram convertidas ou atribuídas em representações binárias para garantir a compatibilidade com a modelagem da rede neuronal, conforme ilustra a Tabela 4-1

Tabela 4-1 Codificação de variáveis categóricas

<b>Tabela de variáveis categóricas</b>	
<b>Varáveis</b>	<b>Cadificação</b>
<b>1) Idade</b>	
Menos de 18 anos	
18-30 anos	
31-45 anos	
46-60 anos	
Mais de 60 anos	
<b>2) Sexo</b>	
Masculino	
Femenino	
Prefero não dizer	
<b>3) Localização</b>	
Covilhã ( centro)	
Covilhã(outros bairros)	
Outras localidades	
<b>4) Estado civil</b>	
Solteira	
Casada	
Divorciado(a)	
Viúvo(a)	
<b>5) Altura (m)</b>	
Normal	
médio risco	
Alto risco	
Não responderam	
<b>6) Peso</b>	
Normal	
médio risco	
Não respondeu	
Alto risco	
<b>7) Medida da cintura</b>	
Menos que 80cm	
Entre 80cm e 88cm	
Entre 89 cm a 93 cm	
Entre 94cm a 102cm	
Mais que 102 cm	
Não respondeu	
<b>8) realiza atividade física regularmente?</b>	
Mais de 30 minutos por dia ou mais de 4 horas por semana	
Menos de 30 minutos por dia ou menos de 4 horas por semana	
Não	
<b>9) consome diariamente frituras, salgados, ou carnes gordas ( incluindo frango com pele)?</b>	
Não	
Sim	

A normalização ou padronização é essencial para garantir que todas as variáveis tenham a mesma escala e contribuam igualmente para a análise, especialmente ao usar algoritmos de aprendizagem de máquina, como redes neurais. Em seguida, a seleção de características é realizada categoricamente, analisando e determinando quais são mais relevantes para a previsão do risco de diabetes. Por fim, os dados são divididos em conjuntos de treino, validação e teste, permitindo treinar o modelo de previsão e avaliar seu desempenho em dados não vistos.

## 4.5 Estatística dos dados

Para melhor entendimento, foi realizada uma análise estatística sobre as questões que constituem o questionário, com o objetivo de uma distribuição mais clara. Visto que, este tipo de estudo classificado como estatística, tem como base criação de uma rede neuronal artificial.

A Figura 4-1 apresenta a distribuição das respostas obtidas em relação à idade dos participantes do estudo. A pesquisa foi conduzida com um total de 161 respostas, e os dados foram classificados em seis categorias principais, menos de 18 anos, 18-30 anos, 31-45 anos, 46-60 anos, mais de 60 anos, e prefiro não dizer.




Figura 4-1 - Distribuição da faixa etária dos participantes

Dos 161 respondentes, a maioria encontra-se na faixa etária de 18 a 30 anos, representando 36,6% das respostas. A faixa etária de 31 a 45 anos também teve uma participação significativa, com 33,5% das respostas. Os participantes com idade entre 46 e 60 anos correspondem a 16,8% do total, enquanto aqueles com mais de 60 anos representam 9,9%. Apenas 3,1% dos respondentes têm menos de 18 anos e nenhum participante escolheu a opção prefiro não dizer.

A Figura 4-2, apresenta a distribuição dos participantes de acordo o sexo, notando que dos 161 respondentes, 51,6% são do sexo masculino, 47,8% do sexo feminino, e 0,6% preferiram não declarar o seu sexo. Esta distribuição indica uma participação ligeiramente maior de

homens em comparação com mulheres, com apenas um pequeno número de participantes optando por não revelar seu sexo.

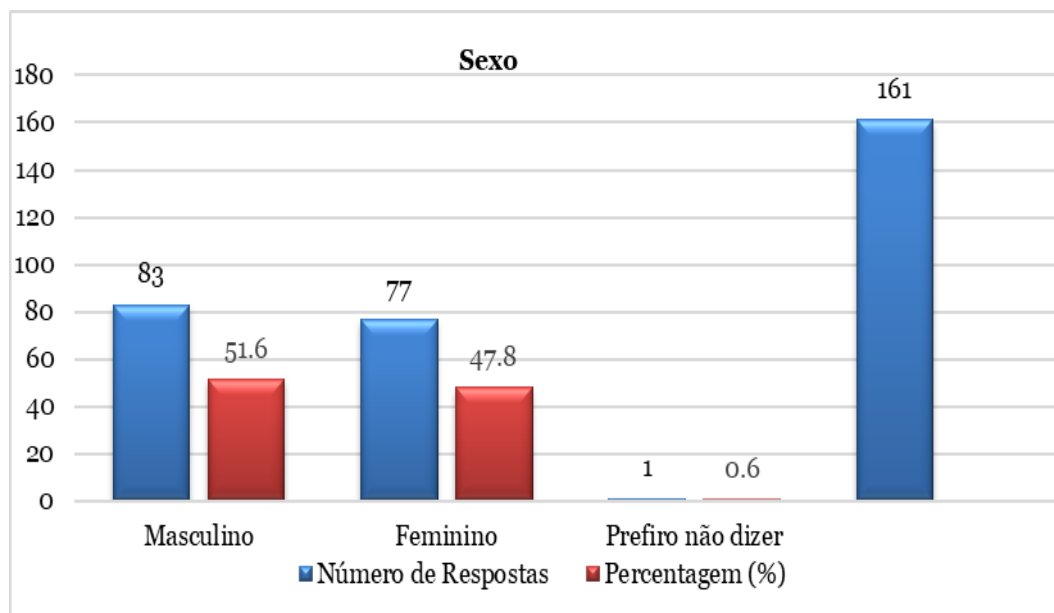


Figura 4-2 Distribuição de acordo o Sexo

A Figura 4-3, ilustra a distribuição das respostas obtidas em relação à localização dos participantes do estudo. Reiterando que a pesquisa foi conduzida com um total de 161 respostas, e os dados foram classificados em três categorias, Covilhã (Centro), Covilhã (Outros bairros) e Outras Localidades.




Figura 4-3 Distribuição de acordo com as localidades da pesquisa

Dos 161 respondentes, 56,5% residem no centro da Covilhã, 31,1% vêm de outros bairros da cidade, e 12,4% são de outras localidades. Esta distribuição destaca uma maior concentração de participantes do centro da cidade, seguida por uma representativa participação de outros bairros e uma menor, mas significativa, contribuição de áreas fora da Covilhã.

A Figura 4-4 ilustra a distribuição sobre o estado civil dos indivíduos. Dos 161 respondentes, 49,7% são solteiros(as), 38,5% são casados(as), 5% são divorciados(as) e 6,8% são viúvos(as). Esta distribuição mostra uma predominância de pessoas solteiras, seguida por uma significativa quantidade de casados, com menores proporções de divorciados e viúvos.

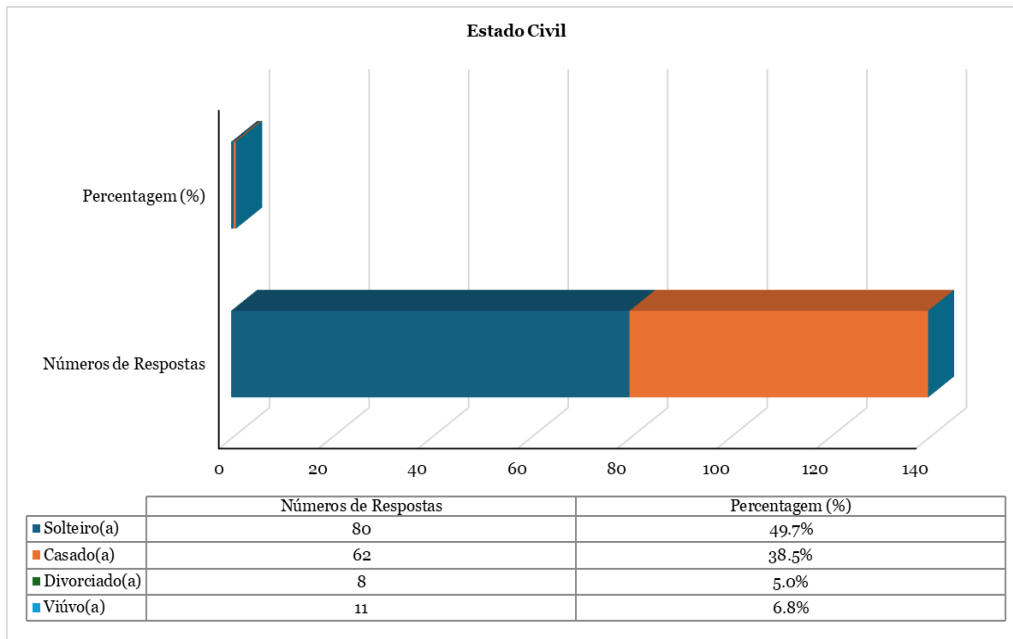


Figura 4-4 Estado civil dos participantes

De acordo a Figura 4-5 apresenta a distribuição dos participantes do estudo em relação à altura, categorizada conforme os níveis de risco. Dos 161 respondentes, 69,6% possuem altura classificada como normal, 28% estão em médio risco, 1,2% estão em alto risco e 1,2% não responderam. Esta distribuição indica que a maioria dos participantes tem altura considerada normal, com uma parcela significativa em médio risco, e uma pequena proporção em alto risco ou que optaram por não responder.

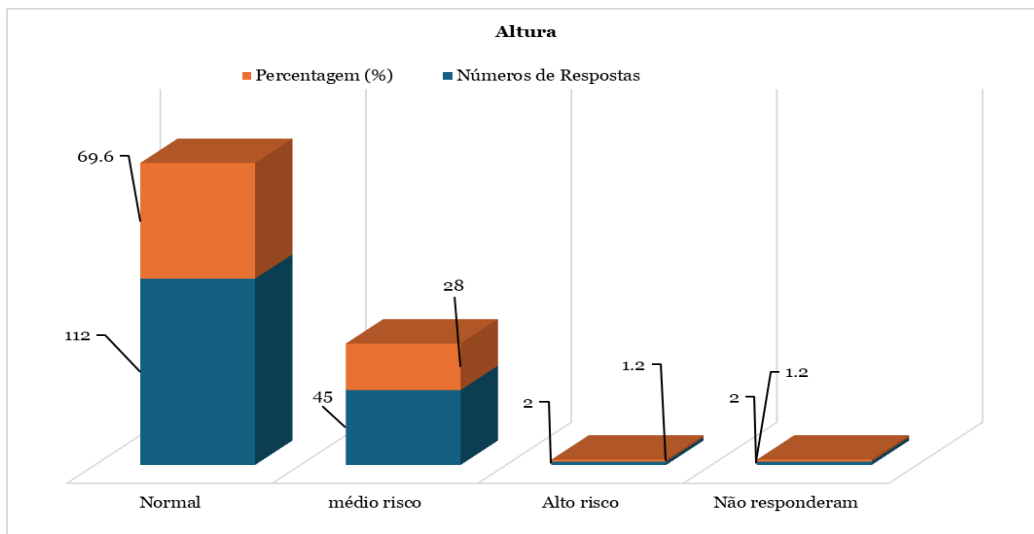


Figura 4-5 Distribuição de acordo altura dos participantes

A Figura 4-6 representa a distribuição das respostas em relação ao peso em diferentes categorias de risco. A maioria das respostas equivale a 71,4% se enquadra na categoria de peso normal, seguida por 24,8% na categoria de médio risco. Apenas uma pequena proporção das respostas caracterizada por 1,2% está na categoria de alto risco. Além disso, 2,5% dos participantes optaram por não responder.




Figura 4-6 Categoria associada ao peso dos participantes

Notavelmente, a Figura 4-7 ilustra a distribuição das respostas sobre as medidas da cintura em diferentes categorias. A maior proporção das respostas foram caracterizada por 28,6% na categoria menos que 80cm, seguida por entre 80cm e 88cm com 24,8%. A categoria entre 89 cm a 93 cm representaram 22,4% das respostas. Uma parcela menor dos participantes equivalente a 8,1% relatou medidas entre 94cm a 102cm. Além disso, 6,2% dos participantes não responderam, enquanto 9,9% indicaram medidas mais que 102 cm.

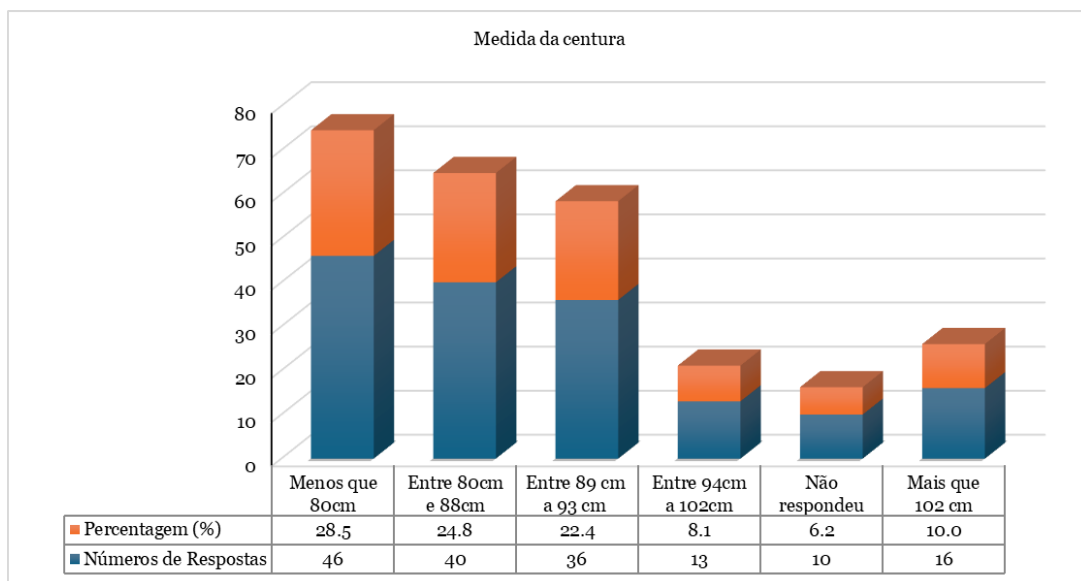


Figura 4-7 Distribuição das medidas da cintura dos participantes

A -Figura 4-8 representa a distribuição das respostas sobre a prática de atividade física regular. Não houve respostas na categoria não, indicando que todos os participantes da pesquisa realizam atividade física regularmente. A maioria das respostas caracterizadas por 53,4% está na categoria mais de 30 minutos por dia ou mais de 4 horas por semana, enquanto 46,6% dos participantes relataram praticar menos de 30 minutos por dia ou menos de 4 horas por semana. Isso sugere que a maioria dos participantes está envolvida em algum nível de atividade física regular, mas as intensidades e durações variam entre os participantes.

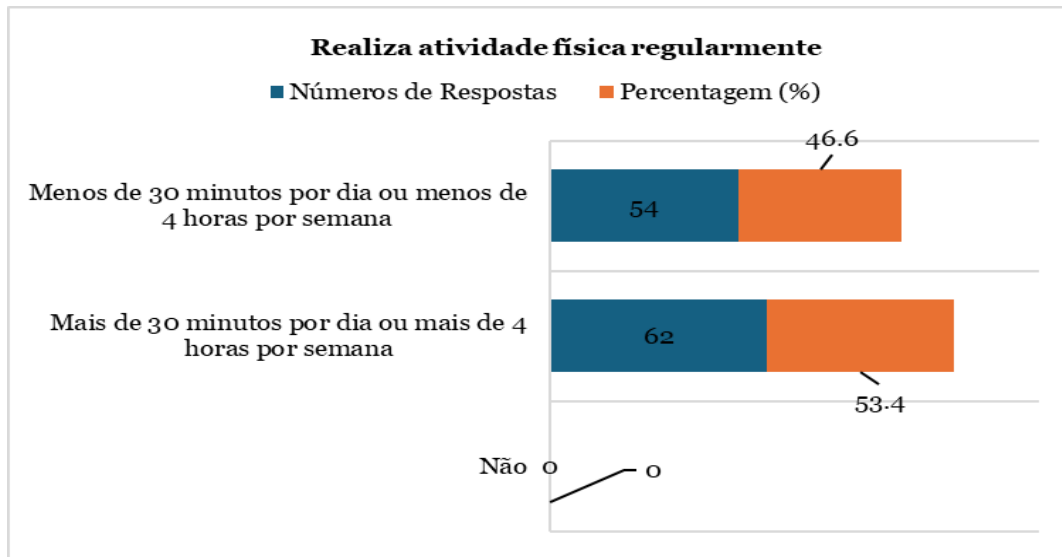


Figura 4-8 Frequência de prática de atividade física regular entre os participantes

A Figura 4-9 mostra a distribuição de acordo com o consumo diário de frituras, salgados ou carnes gordurosas (incluindo frango com pele). A maioria das respostas que foram equivalentes a 69,6% indicou que os participantes não consomem esses alimentos diariamente. Por outro lado, 30,4% dos participantes relataram consumir esses alimentos diariamente.




Figura 4-9 Frequência do consumo diário dos alimentos não saudáveis dos participantes

Na Figura 4-10 mostra as respostas de acordo o consumo diário de vegetais, frutas, legumes ou grãos. A maioria das respostas caracterizando 79,5% indicou que os participantes não consomem esses alimentos diariamente. Em contrapartida, 20,5% dos participantes relataram consumir esses alimentos diariamente.




Figura 4-10 Frequência de consumo diário de alimentos saudáveis dos participantes

A Figura 4-11 representa as respostas de acordo o hábito de fumar. A maioria das respostas caracterizando 78,2% indicou que os participantes nunca fumaram. Entre aqueles que já fumaram, 15,4% relataram ter parado de fumar. Uma pequena proporção dos participantes equivale 5,1% disse fumar de 1 a 10 cigarros por dia, enquanto apenas 1,3% relataram fumar mais que 10 cigarros por dia.

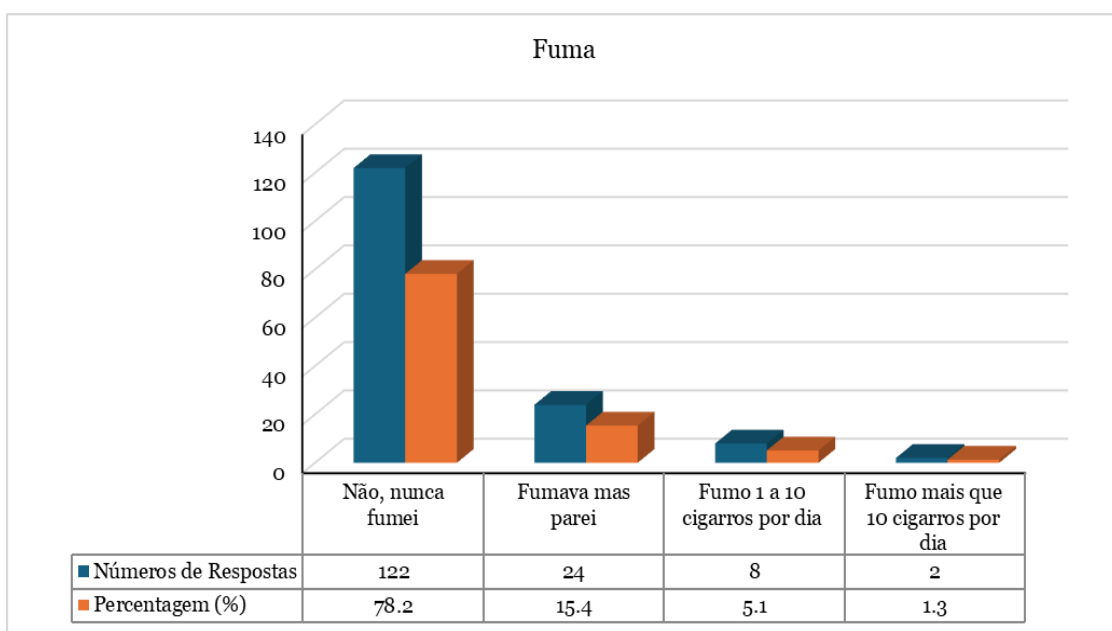


Figura 4-11 Distribuição de uso do tabagismo entre os participantes

A Figura 4-12 mostra o tempo desde que os participantes começaram a fumar regularmente, com um índice indicando uma maioria das respostas equivalente a 74,8%, não se aplica a eles. A pesquisa sobre o tempo desde que os participantes começaram a fumar regularmente, indica que 9,4% dos participantes que fumam têm mais de 21 anos de idade. Entre aqueles que fumam regularmente, a distribuição das respostas foi da seguinte forma, menos de 1 ano teve um total de 6,9%, de 1 a 5 anos equivale á 3,8%, de 6 a 10 anos teve 3,1%, de 11 a 20 anos por 1,9% e mais de 21 anos equivalente a 9,4%.




Figura 4-12 Distribuição hábito de fumar regularmente entre os participantes

A Figura 4-13 ilustra sobre as alterações no nível da glicose. A maioria das respostas caracterizado por 74,7% indicou que sim, ou seja, os participantes já experimentaram alguma alteração nos níveis de glicose. Por outro lado, 25,3% dos participantes relataram nunca terem experimentado tal alteração.




Figura 4-13 Incidência de alterações nos níveis de Glicose entre os Participantes

Na Figura 4-14 apresenta as respostas direcionadas às mulheres sobre o estado de alteração nos níveis de glicose e diabetes durante o período da gestação. Dos participantes, 37,9% responderam que sim, ou seja, já experimentaram alguma alteração nos níveis de glicose ou diabetes durante a gravidez. Por outro lado, 12,4% responderam que não tiveram tais alterações durante a gravidez. Além disso, 49,7% responderam que a pergunta não se aplicava a elas.




Figura 4-14-Distribuição de acordo com os níveis de glicose durante a gravidez

Os participantes com pressão alta ou que usam medicamentos para controlá-la, são representados na Figura 4-15. As respostas sobre se os participantes que têm pressão alta ou usam medicamentos, são indicados da seguinte forma, a maioria das respostas caracterizado por 73,1% indicou que sim, ou seja, os participantes têm pressão alta ou usam medicamentos para controlá-la. Por outro lado, 22,5% dos participantes responderam que não têm pressão alta ou não usam medicamentos para controlá-la. Além disso, uma pequena proporção de cerca de 4,4% respondeu que não sabia dizer.




Figura 4-15 Distribuição dos dados de acordo o uso dos níveis de pressão

Na Figura 4-16 representa as respostas sobre a faixa de pressão arterial que melhor descreve a condição dos indivíduos. A maioria das respostas, isto é 52,2% indicou uma pressão arterial abaixo de 120/80 mmHg, que é considerada normal. 23,6% dos participantes relataram uma pressão arterial na faixa de 120-139/80-89 mmHg, que é considerada pré-hipertensão. Uma proporção menor de 13,0% relatou pressão arterial na faixa de 140-159/90-99 mmHg, que é classificada como hipertensão estágio 1. Apenas uma pequena percentagem de participantes caracterizada por 3,1% relatou uma pressão arterial de 160/100 mmHg, que é classificada como hipertensão estágio 2. Uma resposta indicou uma pressão arterial de 180/120 mmHg ou superior, o que representa uma hipertensão grave. Além disso, 7,5% dos participantes responderam que não sabiam dizer sua faixa de pressão arterial.

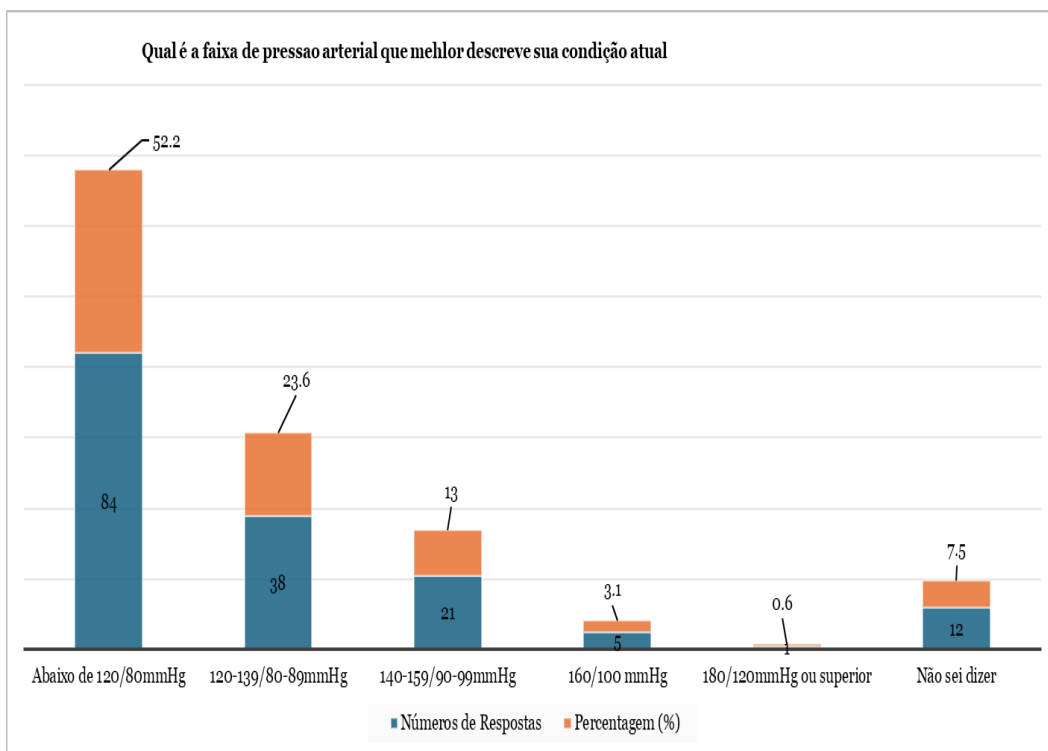


Figura 4-16 Distribuição da faixa de pressão arterial que melhor descreve a condição dos indivíduos

A Figura 4-17 ilustra sobre a hereditariedade de um do parente de primeiro grau (pais, irmãos e filhos), tem como finalidade do estudo ter informações antecipadas se os descendentes têm ou não probabilidade de ter, de forma a termos um controlo eficaz sobre as diabetes. A maioria das respostas indicam que, 66,5% sim, ou seja, os participantes têm pelo menos um parente de primeiro grau com diabetes. Por outro lado, 33,5% dos participantes responderam que não têm nenhum parente de primeiro grau com esta condição




Figura 4-17 Incidência de diabetes entre os parentes do 1º grau

Similar a Figura 4-17 sobre a hereditariedade das diabetes, a Figura 4-18 têm como objetivo, saber sobre os parentes do segundo grau (tios, tias, avós e primos em primeiro grau) com diabetes. Tendo a mesma finalidade de ter o controle, a maioria das respostas, isto é, 60,9% indicam que não, ou seja, os participantes não têm parentes de segundo grau com diabetes. Por outro lado, 39,1% dos participantes relataram ter parentes de segundo grau com esta condição.

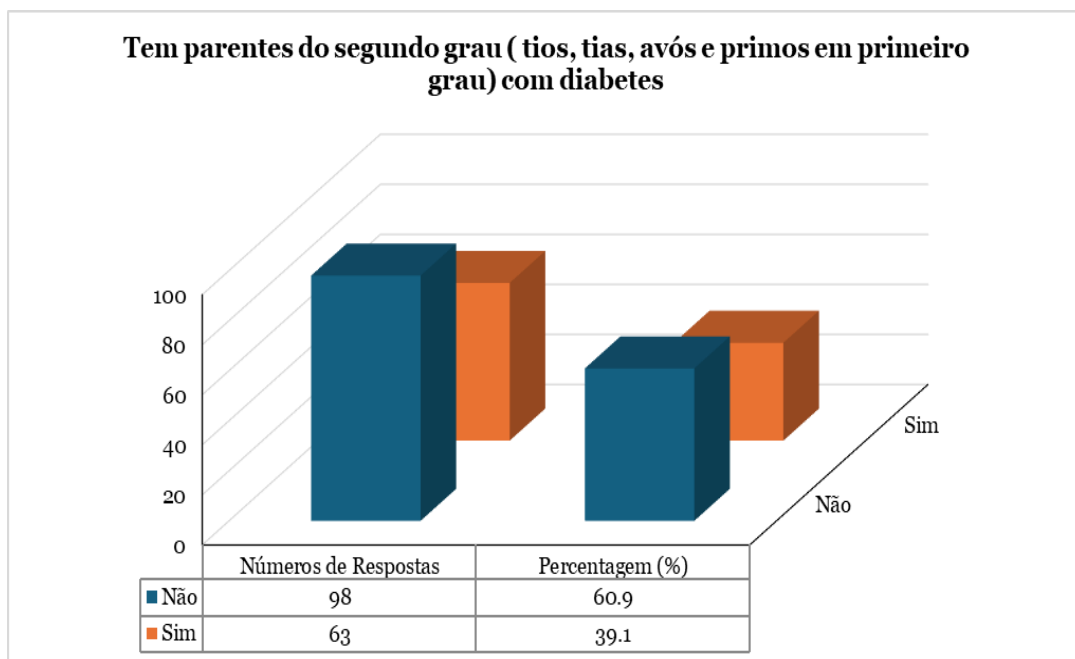


Figura 4-18 Incidência de diabetes entre os parentes do 2º grau

A Figura 4-19 indica o número de respostas realizadas sobre os participantes que foram diagnosticados e os que não foram diagnosticados com diabetes. O quadro é preocupante e merece atenção visto que, a maioria das respostas totalizando 77,0% indicam que não, ou seja, os participantes não foram diagnosticados com diabetes. Por outro lado, 23,0% dos participantes responderam que foram diagnosticados com esta condição.




Figura 4-19 Distribuição de acordo o número os pacientes com e sem diabetes

Na Figura 4-20 indica a representação das respostas concernente os tipos de diabetes que os participantes possuem, caso tenham sido diagnosticados com a condição. Dos participantes que afirmaram ter diabetes, a distribuição das respostas foi de 4,3% relataram ter o Tipo 1, 16,8% relataram ter o Tipo 2, e 3,7% indicaram outro tipo de diabetes. A maioria dos participantes equivale á 75,2% que responderam que têm diabetes relataram que não têm um tipo especificado.

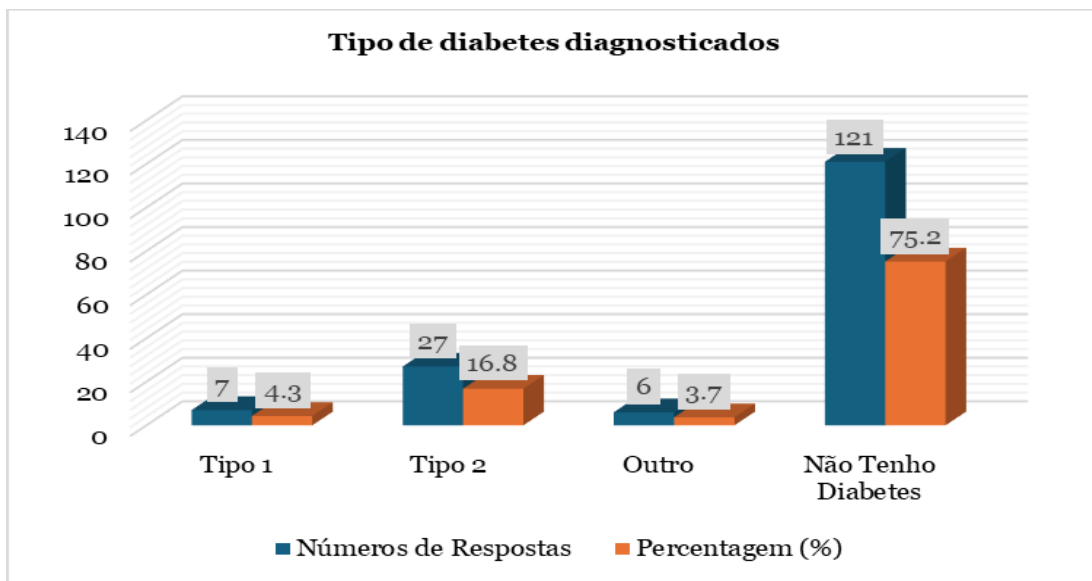


Figura 4-20 Distribuição de acordo com o tipo de diabetes diagnosticado

Na Figura 4-21 mostra as respostas sobre a faixa de rendimento salarial que melhor descreve a situação financeira dos participantes. A maioria dos participantes indicam que 34,0% estão na faixa de rendimento entre 501 á 1000 euros por mês, seguida por 31,4% dos participantes que relataram ganhar menos de 500 euros por mês. Uma parcela significativa dos participantes caracterizado por 20,3% relatou ganhar entre 1001 á 2500 euros por mês. Uma proporção menor dos participantes caracterizado por 5,9% relatou ganhar mais de 2500 euros por mês. Além disso, 8,5% dos participantes preferiram não divulgar sua situação financeira.




Figura 4-21 Distribuição de acordo com a faixa de rendimento salarial

A Figura 4-22, ilustra as respostas sobre os participantes que gostariam de compartilhar mais alguma coisa sobre suas experiências com diabetes. Quase metade dos participantes equivalente a 49,7% responderam que sim indicando que têm algo a compartilhar sobre suas experiências com diabetes. Por outro lado 50,3%, dos participantes, responderam que não têm mais nada a compartilhar. Isso sugere que há um interesse significativo por parte dos participantes em compartilhar suas experiências com diabetes.




Figura 4-22 Partilha de experiência sobre diabetes dos participantes

Resumidamente, é notório que os dados abrangem uma série de áreas, desde hábitos de saúde até informações socioeconômicas. A maioria dos participantes possui peso considerado normal e pratica atividade física regular, embora uma parcela significativa consuma alimentos não saudáveis. Quanto ao tabagismo, a maioria nunca fumou, mas uma pequena proporção ainda mantém esse hábito. A incidência de alterações nos níveis de glicose é considerável, assim como o diagnóstico de diabetes, com a maioria dos participantes relatando ter um parente de primeiro grau com a condição. O rendimento salarial mais comum é entre 501 e 1000 euros por mês, com uma proporção significativa dos participantes expressando interesse em compartilhar suas experiências com diabetes.

#### 4.6 Desenvolvimento do modelo (rede neuronal artificial)

Nesta seção, detalha-se o processo de desenvolvimento da rede neuronal artificial com o objetivo de prever os riscos das diabetes na população da Covilhã. De realçar que este processo compreende diversas etapas.

Elaborou-se um diagrama de fluxo para ilustrar melhor as etapas que constituem este processo, conforme mostra a Figura 4-23

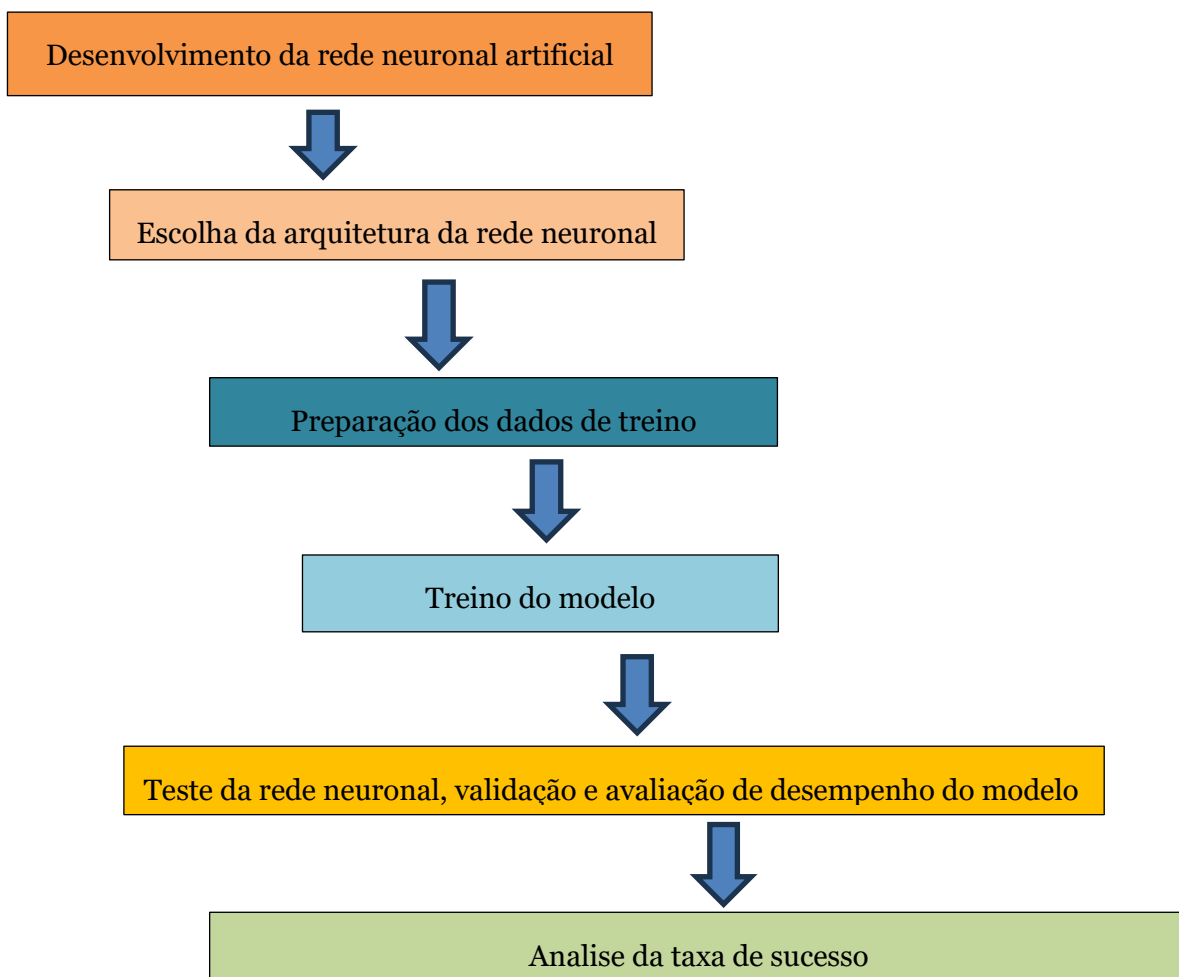


Figura 4-23 - Diagrama de Fluxo. Fonte do Autor

#### **4.6.1 Escolha da arquitetura do modelo (rede neuronal)**

Acredita-se que a escolha da arquitetura da rede neuronal é importante para o sucesso do modelo. Para esta dissertação, considerou-se uma rede *feedforward* com múltiplas camadas, uma vez que estamos diante de um problema de classificação, aconselha-se esta arquitetura. Este tipo de arquitetura permite a propagação de informações de forma unidirecional, desde a camada de entrada até a camada de saída, passando pela camada escondida que realiza as transformações e cálculos necessários para classificação. A mesma é composta por 22 entradas, que são representadas pelos fatores multidimensionais recolhidos por intermédio do questionário dirigido a população em estudo.

Para assegurar a escolha da arquitetura mais eficaz, testaram-se 18 arquiteturas, variando o número de camadas escondidas e a quantidade de neurónios em cada camada, com objetivo de identificar a combinação que apresentasse a maior taxa de sucesso na previsão do risco de diabetes. Para obter um modelo (rede neuronal) robusto e generalista, foram realizados 15 processos de treino para cada arquitetura, tal como ilustra o apêndice A.

#### **4.6.2 Preparação dos dados de treino**

Para este passo, primeiramente o ambiente de trabalho do *Matlab* foi limpo para garantir que não haja interferências de possíveis variáveis ou figuras executadas anteriormente. Em seguida, leu-se os dados anteriormente preparados em uma folha do excel relacionada com o questionário dirigido à população e com números de indivíduos que constituem o nosso estudo, para este passo usou-se a função *Xlsread*, de seguida converteu-se a matriz das células lida para uma matriz numérica com ajuda da função *Cell2mat*.

Configurou-se os dados de entradas e saída, cujo as entradas (X) foram formadas pelas questões 1 a 18 (que correspondem as seguintes questões: idade, sexo, localização, estado civil, altura, peso, medida da cintura, realiza atividade regularmente?, consome diariamente frituras, salgados ou canes gordas ( incluindo pele)?, consome diariamente vegetais, frutas, legumes ou grãos?, fuma?, se fuma, desde quando começou a fumar regularmente?, algumas vez teve alteração do seu nível de glicose ou diabetes durante a gravidez?, tem pressão alta ou toma remédios para controla-lo?, qual é a faixa de rendimento que melhor descreve a sua condição feneceria?, tem parentes em primeiro grau(pais, irmãos e filhos ) com diabetes ?, tem parentes em segundo grau ( avos , tios e primos em primeiro grau) com diabetes?) e a questão 21 (que corresponde, qual faixa de rendimento salarial melhor descreve sua situação financeira) da matriz do dados, enquanto que as saídas são caracterizadas pela questão 19 que corresponde se o indivíduo foi diagnosticado com diabetes.

### 4.6.3 Treino do modelo

Utilizou-se a função de ativação tangente hiperbólica (*tansig*), que é adequada para transformar os dados normalizados entre -1 e 1, oferecendo boas propriedades de diferenciação e convergência. Para o treino, utilizou-se o algoritmo de treino *Levenberg-Marquardt* (*trainln*), que é amplamente reconhecido pela sua eficiência e velocidade na convergência em problemas de otimização. Foram estabelecidos critérios de paragem com um número máximo de mil (1000) iterações e uma quantidade máxima de 10 falhas consecutivas. Também se configurou a função de divisão dos dados de forma aleatória, bem como as proporções para treino, validação e teste.

De acordo com os dados fornecidos na estatística, analisou-se 161 indivíduos que foram distribuídos em três conjuntos distintos, treino, validação e teste. O conjunto de treino foi o equivalente a 112 indivíduos, representando assim a 69,575% do total, realçando que este conjunto se usa para treinar as diversas arquiteturas. Em seguida, definiu-se o conjunto de validação que inclui 28 indivíduos, que correspondiam 17,93% do total, com objetivo de treinar os hiperparâmetros das arquiteturas e prevenir o sobreajuste, o que se chama de *overfitting*. Assim sendo, o conjunto de teste foi constituído por 21 indivíduos, o que equivale a 13,04% do total da amostra, este conjunto usou-se para avaliar o desempenho final do modelo. Estas distribuições foram feitas de acordo as práticas comuns nas análises de dados para a criação de uma rede neuronal artificial, garantindo que cada conjunto tenha uma quantidade suficiente de amostra para produzir resultados estatisticamente significativos, conforme mostra a Tabela 4-2.

Tabela 4-2 – Distribuição dos conjuntos de dados (total: 161)

Conjunto de Dados	Quantidades	Percentagem (%)
Treino	112	69,57%
Validação	28	17,39%
Teste	21	13,04%

Fez-se a normalização das entradas e saídas de maneira a garantir que os valores se apresentam dentro de uma faixa adequada para o treino do modelo, que é considerada de -1 e 1. Posteriormente, treinou-se a rede neuronal com dados de entradas e saída (*x*) e (*y*). Realçando que estes passos foram feitos para todas as arquiteturas treinadas.

### 4.6.4 Teste, validação e avaliação de desempenho do modelo

Após ter feito o treino, o modelo foi testado com um conjunto diferente de dados para avaliar seu desempenho. Os dados correspondentes para o teste foram selecionados dos indivíduos 141 a 161. Os valores de saída da rede neuronal foram treinados para 0 ou 1. De seguida fez-se

a visualização dos resultados e avaliação do modelo. Posteriormente, sentiu-se a necessidade de analisar a taxa de sucesso comparando as saídas da rede com os valores reais. Esta análise foi crucial para entender o desempenho da rede neuronal e identificar pontos fracos do modelo (rede neuronal). Os índices dos indivíduos onde o modelo falhou foram identificados e anotados, permitindo uma avaliação detalhada das situações onde o modelo não conseguiu fazer previsões corretas.

#### 4.6.5 Análise da taxa de Sucesso

A taxa de sucesso, foi cuidadosamente registada de maneira fazer a comparação entre os resultados obtidos entre as diferentes arquiteturas. Acredita-se que esta análise comparativa é fundamental para determinar quais arquiteturas de rede neuronal são mais eficazes para concretização do objetivo em estudo. Conforme mostra a Tabela 4.2 as diferentes arquiteturas criadas e suas respectivas taxas de sucesso analisadas. Esta tabela ilustra visualmente o desempenho de cada arquitetura, permitindo uma fácil comparação entre elas. A avaliação inclui modelo com várias camadas escondidas e diversos neurónios, visando encontrar a combinação que proporcionasse para nosso estudo o melhor desempenho. Os resultados estão apresentados na Tabela 4.2 onde podemos ver a arquitetura com a taxa de sucesso máximo equivale a 79,68% , enquanto a taxa mínima é de 72,38%.

Tabela 4-3 Diferentes tipos de arquiteturas neuronais e suas respectivas taxas de sucessos

Taxa média de sucesso	Arquiteturas
76,82542	10
75,87304	20
74,28574	30
79,68256	40
75,23812	50
75,8724	60
75,2381	70
73,65082	80
75,23812	90
72,38098	100
76,82542	10 20
75,87303333	10 30
73,33336	10 40
76,82542	50 60
77,46034	45
79,04764	25
78,09526	50 20
74,92066	50 40

Assim sendo, este processo de análise e comparação das diferentes arquiteturas é crucial para a otimização do modelo. Ao identificar quais arquiteturas apresentam as melhores taxas de sucesso, garantindo maior precisão e eficácia na previsão.

## Capítulo 5

Neste capítulo, são enunciados os resultados e a discussão dos mesmos, com objetivo de obter um estudo conclusivo desta dissertação.

### Análise dos resultados e discussão

#### 5.1 Resultados

Finalizando o processamento dos dados, o treino e a leitura das saídas das diversas arquiteturas, chegou-se às seguintes análises. Foram identificadas falhas constantes em 3 indivíduos, com números de identificação 8, 11 e 12. Esses resultados foram comparados com os valores reais das respostas fornecidas pelos indivíduos do local em estudo, dos quais 23% foram diagnosticados com doença abordada e 77% não foram diagnosticados. Entre as diversas arquiteturas, considerou-se apenas uma, que se tornou o modelo final. Este modelo apresentou, então, uma precisão de 90,5% nas respostas corretas. A certeza com que o modelo emite as respostas, com base na taxa de sucesso máxima de 79,7%.

#### 5.2 Discussão

A utilização de Inteligência Artificial (IA), particularmente de Redes Neurais Artificiais (RNAs), apresenta um potencial transformador na área da saúde, especificamente na previsão e gestão de riscos de doenças crônicas como a diabetes. No presente estudo, desenvolveu-se um modelo de rede neural que alcançou uma precisão de 90,5% de acordo com os quinze (15) runs de cada arquitetura, conforme o apêndice B, Tabela apêndice B-1, da previsão dos riscos de diabetes na população da Covilhã, demonstrando a eficácia da IA na análise de dados complexos e heterogêneos. Este resultado sugere que o modelo é capaz de capturar padrões de risco em fatores multidimensionais, oferecendo um suporte significativo à detecção precoce da doença e à implementação de medidas preventivas na comunidade local.

No entanto, as falhas recorrentes identificadas nos indivíduos 8, 11 e 12 indicam que o modelo apresenta dificuldades em lidar com algumas características específicas destes casos. Estas falhas podem ser atribuídas a correlações particulares nos dados destes indivíduos, como variáveis demográficas ou outras variáveis que se destacam dos restantes. Esta variação pode ter contribuído para que o modelo tratasse estes casos como exceções, apontando para a necessidade de uma exploração mais profunda das variáveis envolvidas e para uma avaliação de possíveis ajustamentos que possam melhorar a generalização do modelo.

Para além disso, as dificuldades em prever corretamente estes casos podem estar relacionados com problemas de subajustamento ou sobreajustamento. Embora estes problemas tenham sido cautelados durante o processo de modelação, podem ter resultado de um desequilíbrio nos dados de treino. Estudos futuros poderão beneficiar de uma análise mais aprofundada sobre a distribuição das variáveis e a adição de dados provenientes de outras fontes, para melhorar o equilíbrio entre os diferentes perfis de risco e reduzir potenciais tendências. A taxa de sucesso máxima de 79,7% são indicadores de robustez do modelo. Esta taxa de sucesso demonstra que o modelo consegue apresentar respostas consistentes e acertadas na maioria dos casos, proporcionando confiança na sua capacidade de identificar padrões de risco de diabetes. Este desempenho reforça a aplicabilidade do modelo em contextos semelhantes, onde se pretende realizar previsões para populações com características comparáveis às da Covilhã. A presente investigação alinha-se com estudos como de Ep et al. [24] que demonstram eficácia das redes neurais na previsão de diabetes, incluindo redes densas e convolucionais. Os dados indicados nestes trabalhos são insuficientes, mas na literatura é possível obter melhores resultados, e sublinham a capacidade das RNAs para identificar padrões complexos em dados de saúde, o que colabora com os resultados obtidos neste trabalho e reforça o papel destas tecnologias na melhoria da saúde pública.

Contudo, os desafios inerentes à implementação prática de RNAs não podem ser ignorados. A qualidade dos dados é essencial, pois a presença de ruído ou de informações incompletas pode prejudicar a precisão do modelo, tal como reportado no estudo de Haghi et al. [35]. Para além disso, a explicabilidade das redes neurais permanece um desafio, uma vez que a natureza das RNAs pode tornar difícil interpretar como as previsões são geradas. Este fator é crítico para aceitação do modelo em ambientes clínicos, onde se exige transparência para a tomada de decisões médicas. Os resultados deste estudo sugerem que os modelos de IA têm um grande potencial para apoiar iniciativas de prevenção de doenças e, em particular, para a avaliação do risco de diabetes em comunidades específicas. Com base na precisão demonstrada e no potencial de replicabilidade deste modelo, é possível que, no futuro, as redes neuronais artificiais se tornem uma ferramenta valiosa no diagnóstico precoce da diabetes e de outras doenças crónicas. Tal avanço poderia facilitar ações de saúde pública direcionadas à intervenção preventiva, permitindo medidas mais personalizadas e eficazes, o que é essencial para a gestão de doenças crónicas numa população com características tão diversas como a da Covilhã.

## Capítulo 6

Neste capítulo, são enunciadas as conclusões resultantes de todo trabalho, demonstrado nesta dissertação. Além disso, são apresentadas e sugeridas propostas para trabalhos futuros em contexto do estudo realizado.

### Conclusão

#### 6.1 Considerações finais

O presente trabalho teve como objetivo refletir sobre o fato das máquinas estarem simulando comportamentos humanos. Para isso, desenvolver uma rede neuronal artificial para prever o risco das diabetes na população da Covilhã, com base nos fatures multidimensionais.

Concluiu-se que à medida que a inteligência artificial avança, as máquinas estão se tornando cada vez mais humanizadas, demonstrando habilidades que antes eram artificiais. Técnicas como lógica *fuzzy*, algoritmos genéticos, robótica, redes neuronais artificiais e outros tópicos ligados á IA são fundamentais para esta evolução, permitindo que as máquinas aprendam, se adaptem e tomem decisões em situações complexas e ambíguas. Estas capacidades, que imitam o pensamento humano, resultam em máquinas capazes de realizar tarefas que vão desde o diagnóstico de doenças até a interação social, como é o caso dos robôs humanoides e dos sistemas de IA sofisticados utilizados em diversas áreas.

Portanto, o processo de humanização das máquinas também está presente na robótica, onde vemos robôs industriais e de serviços se aproximando cada vez mais das habilidades humanas em precisão, adaptabilidade e interação social. Robôs humanoides como a Sophia e o CyberOne exemplificam esta tendência, sendo capazes de expressar emoções, reconhecer rostos e realizar tarefas educacionais ou de assistência médica com uma compreensão profunda do contexto humano.

Explorou-se o uso de RNA na previsão de riscos associados as diabetes, demonstrando o potencial desta tecnologia no campo da saúde. A análise de dados realizada revelou que as RNAs são capazes de processar poucos e muitos volumes de informações de maneira eficaz, identificando padrões complexos que podem não ser facilmente discerníveis por métodos tradicionais. A aplicação prática na população da Covilhã resultou em uma taxa de acerto de 90,5% confirmando, conforme mostra o apêndice B, Tabela apêndice B-1 e a viabilidade do uso de RN para prever riscos de diabetes com alta precisão.

Portanto, as redes neurais artificiais têm um potencial significativo na previsão de riscos de diabetes, oferecendo uma ferramenta valiosa para a detecção precoce e intervenção. No entanto, para maximizar sua eficácia e aceitabilidade, é essencial abordar questões relacionadas à qualidade dos dados, explicabilidade dos modelos, generalização e privacidade. Avanços contínuos na pesquisa e na tecnologia poderão superar esses desafios, tornando a previsão de doenças com RNA uma prática padrão na medicina preventiva.

Contudo, este tipo de aplicação da inteligência artificial ainda necessita de mais estudos e testes. O próximo passo poderá consistir em um estudo com uma metodologia semelhante, mas com uma amostra significativamente maior, para que esta rede neuronal possa ser utilizada. Desta forma, seria possível um treino mais completo da rede, e consecutivamente uma resposta ainda mais fiável.

### **6.1.1 Sugestões de trabalhos futuros**

Esta sessão descreve algumas abordagens que podem ser usadas para melhorar a classificação em redes neuronais artificiais. Acredita-se que esta dissertação possa servir de guia para futuros pesquisadores que desejam seguir ou desenvolver o mesmo objetivo. Pode se destacar as seguintes melhorias:

- A primeira melhoria é utilizar um maior número de dados, coletados em sistemas de saúde como hospitais, centros médicos, sistema online de controlo de doenças. Isso evita dificuldades na recolha de dados por meio de questionário dirigido diretamente à população visto que são dados confidenciais e as pessoas nem sempre estão dispostas a fornecer estas informações por esta via. Para esta dissertação, foram considerados dados da população da Covilhã. Desta forma, aconselha-se que os futuros pesquisadores recolham dados em hospitais e centros de saúde, de maneira obter um maior número de pacientes com diabetes, assim, apresentar maior eficácia do modelo desenvolvido.
- Recomenda-se realizar testes de comparação com técnicas diferentes de prevenção de risco de diabetes, tal como usado na plataforma SNS 24, apdp, etc.

## Referências bibliográficas

- [1] Allen, A., Iqbal, Z., Green-Saxena, A., Hurtado, M., Hoffman, J., Mao, Q., & Das, R. (2022). Prediction of diabetic kidney disease with machine learning algorithms, upon the initial diagnosis of type 2 diabetes mellitus. *BMJ Open Diabetes Research and Care*, 10(1), e002560.
- [2] Almenara, I. (2022, agosto 11). Xiaomi anuncia o CyberOne, robô-humanoide que promete reconhecer emoções (D. Ciriaco, Ed.). Disponível em: <https://canaltech.com.br/robotica/xiaomi-anuncia-o-cyberone-robo-humanoide-que-promete-reconhecer-emocoes-222888/>
- [3] Aragão, M. D. M. (2023). *O paradoxo atual dos humanos a se tornarem máquinas versus as máquinas a se tornarem humanas* (Master's thesis, Universidade da Beira Interior (Portugal)).
- [4] Araújo, L. F. D. (2021). Uma abordagem baseada em redes neurais artificiais para diagnóstico de diabetes.
- [5] Arcajo, C. A., Gutierrez, V. O., Assis, R. P., Moreira, T. F., Costa, P. I., Baviera, A. M., & Brunetti, I. L. (2014). Piperine, a natural bioenhancer, nullifies the antidiabetic and antioxidant activities of curcumin in streptozotocin-diabetic rats. *PLoS One*, 9(12), e113993.
- [6] Barreto, R. G., Marinho, G. M. G. A., Barreto, G. F. M., Barreto, R. G., Aversari, L. O. C., & Dantas, B. L. (2018). Utilizando Redes Neurais Artificiais para o Diagnóstico de Câncer Cervical. *REVISTA SAÚDE & CIÊNCIA*, 7(2), 59-67.
- [7] Batista, M. H. J., de Sousa, L. P., de Souza, D. M. D., Silva, R. O., dos Santos Lima, E., Nunes, T. S., ... & Rocha, M. A. (2021). Diabetes Gestacional: origem, prevenção e riscos. *Brazilian Journal of Development*, 7(1), 1981-1995.
- [8] Baviera, M., Santalucia, P., Cortesi, L., Marzona, I., Tettamanti, M., Avanzini, F., ... & Roncaglioni, M. C. (2014). Sex differences in cardiovascular outcomes, pharmacological treatments and indicators of care in patients with newly diagnosed diabetes: analyses on administrative database. *European journal of internal medicine*, 25(3), 270-275.
- [9] Braga, A. D. P., Ludermir, T. B., & Carvalho, A. C. P. D. L. F. D. (2000). Redes neurais artificiais: teoria e aplicações.
- [10] Brandt, M., & Medeiros, M. B. B. (2010). Folksonomia: esquema de representação do conhecimento? *Transinformação*, 22, 111-121.

- [11] Buse, J. B., Wexler, D. J., Tsapas, A., Rossing, P., Mingrone, G., Mathieu, C., ... & Davies, M. J. (2020). 2019 update to: management of hyperglycemia in type 2 diabetes, 2018. A consensus report by the American Diabetes Association (ADA) and the European Association for the Study of Diabetes (EASD). *Diabetes care*, 43(2), 487-493.
- [12] Carvalho, M. A. D. (2010). Discretização de atributos contínuos em sistemas de informação utilizando algoritmos genéticos para a aplicação da Teoria de Conjuntos Aproximados.
- [13] Chawla A, Chawla R, Jaggi S. Microvascular and macrovascular complications in diabetes mellitus: Distinct or continuum? *Indian J Endocrinol Metab.* 2016 Jul-Aug;20(4):546-51. doi: 10.4103/2230-8210.183480. PMID: 27366724; PMCID: PMC4911847.
- [14] Chiang, J. L., Kirkman, M. S., Laffel, L. M., & Peters, A. L. (2014). Type 1 diabetes through the life span: a position statement of the American Diabetes Association. *Diabetes care*, 37(7), 2034.
- [15] Córdón, O., del Jesus, M. J., Herrera, F., & Lozano, M. (1998). Modelado cualitativo utilizando una metodología evolutiva de aprendizaje iterativo de bases de reglas difusas. *Inteligencia Artificial, Revista Iberoamericana de Inteligencia Artificial*, 5, 56-61.
- [16] Da Silva, L. M., Gonçalves, R. M., Ferreira, L. M., da Silva, E. J. A., & da Silva, B. Q. (2019). Estado da arte dos fundamentos e ideias da lógica fuzzy aplicada as ciências e tecnologia. *Revista Brasileira de Geomática*, 7(3), 149-169.
- [17] Da Silveira Medeiros, L. S. (2016). Importância do controle glicêmico como forma de prevenir complicações crônicas do diabetes mellitus. *RBAC*, 48(3), 262-7.
- [18] De Freitas Alves, R. M., da Silva, F. N. R., Mota, D. P., Mysmar, D., & de Freitas Alves, S. M. (2017). Seleção de pessoas por meio de algoritmos genéticos. *Revista de Administração da Universidade Federal de Santa Maria*, 10(2), 307-317.
- [19] De Lacerda, E. G., & De Carvalho, A. C. P. L. F. (1999). Introdução aos algoritmos genéticos. *Sistemas inteligentes: aplicações a recursos hídricos e ciências ambientais*, 1, 99-148.
- [20] De Lima, L. M. M., de Toledo Vianna, R. P., & de Moraes, R. M. (2019). Identificação das anomalias congênitas baseado em um modelo de decisão a partir de redes neurais artificiais. *Journal of Health Informatics*, 11(1).

- [21] Do Nascimento Neto, C. D., Borges, K. F. L., de Oliveira Penina, P., & Pereira, A. L. (2020). Inteligência artificial e novas tecnologias em saúde: desafios e perspectivas. *Brazilian Journal of Development*, 6(2), 9431-9445.
- [22] Dos Santos, T. L., Costa, C. V., Amorim, E. S., Gomes, E. B., da Fonseca, H. T. A., de Souza, L. C. A., ... & de Oliveira Cardoso, A. V. (2021). Principais fatores de risco relacionados ao desenvolvimento de diabetes gestacional. *Revista Eletrônica Acervo Enfermagem*, 16, e9537-e9537.
- [23] Eng., E. (2008). Controle feedforward-feedback aplicado as colunas de absorção do processo de produção de etanol por fermentação (Doctoral dissertation, [sn]).
- [24] EP, P., K, S., Karthik, S., MV, K., P, D., Reddy S, B., ... & Sahile, K. (2022). Implementation of Artificial Neural Network to Predict Diabetes with High-Quality Health System. *Computational intelligence and neuroscience*, 2022(1), 1174173.
- [25] Excelência robótica (2016). Sistema robótico da Vinci: de que se trata? Disponível em: <https://www.excelenciarobotica.pt/pt/sistema-robotico-da-vinci/de-que-se-trata>.
- [26] Falcão, J. V. R., de Ávila Moreira, V., de Ávila Ramos, C., & de Oliveira Santos, F. A. (2019). Redes neurais deep learning com tensorflow. *RE3C-Revista Eletrônica Científica de Ciência da Computação*, 14(1).
- [27] Federação Intencional de Diabetes. (2023). IDF Diabetes Atlas (10th ed). Disponível em <https://diabetesatlas.org>.
- [28] Fleck, L., Tavares, M. H. F., Eyng, E., Helmann, A. C., & Andrade, M. D. M. (2016). Redes neurais artificiais: Princípios básicos. *Revista Eletrônica Científica Inovação e Tecnologia*, 1(13), 47-57.
- [29] Flório, V. (2018). Ficção, passado e futuro dos robôs. *Ciência e Cultura*, 70(1), 64-65.
- [30] Fonseca, A. U., Felix, J. P., Vieira, G. S., Rocha, B. M., Nogueira, E. A., Araújo, C. E. E., ... & Soares, F. (2023). Diagnosticando Tuberculose com Redes Neurais Artificiais e Recursos BPPC. *Journal of Health Informatics*, 15(Especial).
- [31] Gaio, D. E. (2022). Análise comparativa das técnicas de implementação de arquiteturas da função sigmóide.

- [32] Galindo, J., Urrutia, A., & Piattini, M. (2004). Fuzzy aggregations and fuzzy specializations in Eindhoven fuzzy EER model. In *Advanced Topics in Database Research*, Volume 3 (pp. 106-127). IGI Global.
- [33] Gonçalves Bertonhi, L., Chioda, J., & Dias, R. (2018). Diabetes mellitus tipo 2: aspectos clínicos, tratamento e conduta dietoterápica Type 2 Diabetes mellitus: clinical aspects, treatment and dietary management. *Revista Ciências Nutricionais Online*, (2), 1-10.
- [34] Guerra, J. V. V., Alves, V. H., Valete, C. O. S., Rodrigues, D. P., Branco, M. B. L. R., & dos Santos, M. V. (2019). Diabetes gestacional e assistência pré-natal no alto risco. *Revista de Enfermagem UFPE on line*, 13(2), 449-454.
- [35] Haghi, M., Thurow, K., & Stoll, R. (2017). Wearable devices in medical internet of things: scientific research and commercially available devices. *Healthcare informatics research*, 23(1), 4-15.
- [36] Haykin, S. (2001). Kalman filters. *Kalman filtering and neural networks*, 1-21.
- [37] Júnior, G. D. B. V., Fileni, C. H. P., & Passos, R. P. (2020). Redes neurais recorrentes: aplicabilidade na análise do movimento humano e na saúde. *Revista CPAQV-Centro de Pesquisas Avançadas em Qualidade de Vida*, 12(1).
- [38] Kaufman, D. (2019). A inteligência artificial irá suplantará a inteligência humana?. *Estação das letras e cores EDI*.
- [39] Kourou, K., Exarchos, T. P., Exarchos, K. P., Karamouzis, M. V., & Fotiadis, D. I. (2015). Machine learning applications in cancer prognosis and prediction. *Computational and structural biotechnology journal*, 13, 8-17.
- [40] Lacity, M. C., & Willcocks, L. P. (2016). A new approach to automating services. *MIT Sloan Management Review*, 58(1), 41-49.
- [41] Lima, W., Palmeira, R. B., & Gonçalves, I. B. (2018). Computação cognitiva: um grande alicerce no desenvolvimento de tratamentos médicos eficazes. *Tecnologias em projeção*, 9(2), 61-77.
- [42] Linden, R. (2006). Algoritmos genéticos: uma importante ferramenta da inteligência computacional. Brasport.
- [43] Machado, A. P. M. C., Santos, A. C. G., Carvalho, K. K. A., Gondim, M. P. L., Bastos, N. P., Rocha, J. V. S., ... & de Prince, K. A. (2019). Avaliação da adesão ao tratamento

- de pacientes com diabetes mellitus e seus fatores associados. *Revista Eletrônica Acervo Saúde*, (19), e565-e565.
- [44] Malta, D. C., Iser, B. P. M., Andrade, S. S. C. D. A., Moura, L. D., Oliveira, T. P., & Bernal, R. T. I. (2014). Tendência da prevalência do diabetes melitos autorreferido em adultos nas capitais brasileiras, 2006 a 2012. *Epidemiologia e Serviços de Saúde*, 23, 753-760.
- [45] Maraschin, J. D. F., Murussi, N., Witter, V., & Silveiro, S. P. (2010). Classificação do diabete melito. *Arquivos Brasileiros de Cardiologia*, 95, 40-46.
- [46] Marcos; Rivero Gestal (Daniel; Rabuñal, Juan Ramón; Dorado, Julián; Pazos, Alejandro), & Gestal, M. (2010). *Introducción a los algoritmos genéticos y la programación genética* (p. 32). Coruña: Universidade da Coruña.
- [47] Marinho, N. B. P., Vasconcelos, H. C. A. D., Alencar, A. M. P. G., Almeida, P. C. D., & Damasceno, M. M. C. (2013). Risco para diabetes mellitus tipo 2 e fatores associados. *Acta Paulista de Enfermagem*, 26, 569-574.
- [48] Martins, V. H. P. (2020). Algoritmo paralelo para análise comportamental de utilizadores de mídias sociais na detecção de distúrbios mentais.
- [49] Matsunaga, V. Y. (2012). *Curso de Redes Neurais utilizando o MATLAB*. Belém do Pará.
- [50] Miranda, F. A., De Freitas, S. R. C., & Faggion, P. L. (2009). Integração e interpolação de dados de anomalias ar livre utilizando-se a técnica de RNA e krigagem. *Boletim de Ciências Geodésicas*, 15(3), 428-443.
- [51] Morrell, A. L. G., Morrell-Junior, A. C., Morrell, A. G., Mendes, J., Freitas, M., Tustumi, F., & Morrell, A. (2021). Evolução e história da cirurgia robótica: da ilusão à realidade. *Revista do Colégio Brasileiro de Cirurgiões*, 48, e20202798.
- [52] Pozo, A., Cavalheiro, A. F., Ishida, C., Spinosa, E., & Rodrigues, E. M. (2005). *Computação evolutiva*. Universidade Federal do Paraná, 61p.(Grupo de Pesquisas em Computação Evolutiva, Departamento de Informática-Universidade Federal do Paraná).
- [53] Ribeiro, J. M. (2016). análise de falhas em motores de indução trifásica, através do método de detecção de falhas análise de vibração, utilizando controle por lógica fuzzy.

- [54] Romano, V. F., & Dutra, M. (2002). Introdução a robótica industrial. *Robótica Industrial: Aplicação na Indústria de Manufatura e de Processo*, São Paulo: Edgard Blücher, 1-19.
- [55] Rosas, M. A., Bezerra, A. F. B., & Duarte-Neto, P. J. (2013). Uso das redes neurais artificiais na aplicação de metodologia para alocação de recursos da saúde. *Revista de Saúde Pública*, 47, 128-136.
- [56] Rossett, T. C. W., De Matos, T., Rotta, Y. V., Gonçalves, K., Pescador, R. A., & Boas, M. V. (2022). Prevalência do diabetes mellitus gestacional em um ambulatório de alto risco do oeste do Paraná. *Revista Thêma et Scientia*, 12(1).
- [57] Russell Stuart, J., & Norvig, P. (2009). *Artificial intelligence: a modern approach* (p. 1152). Upper Saddle River: Prentice Hall.
- [58] Saito, É. K. (2019). Conectividade cerebral para o controle online de interfaces Cérebro-Máquina.
- [59] Santos, C.B. (2026) o fantástico mundo do open hardware.
- [60] Schmidt, M. I., Duncan, B. B., Hoffmann, J. F., Moura, L. D., Malta, D. C., & Carvalho, R. M. S. V. D. (2009). Prevalência de diabetes e hipertensão no Brasil baseada em inquérito de morbidade auto-referida, Brasil, 2006. *Revista de Saúde Pública*, 43, 74-82.
- [61] Sharma, T., & Shah, M. (2021). A comprehensive review of machine learning techniques on diabetes detection. *Visual Computing for Industry, Biomedicine, and Art*, 4(1), 30.
- [62] Silva Junior, J. R. D., Souza, A. S. R., Agra, K. F., Cabral Filho, J. E., & Alves, J. G. B. (2016). Diabetes mellitus gestacional: importância da produção de conhecimento. *Revista Brasileira de Saúde Materno Infantil*, 16, 85-87.
- [63] Silva, N. F. D. C. D., Vianna, C. M. D. M., Oliveira, F. S. G. D., Mosegui, G. B. G., & Rodrigues, M. P. D. S. (2017). Fuzzy Visa: um modelo de lógica fuzzy para a avaliação de risco da Vigilância Sanitária para inspeção de resíduos de serviços de saúde. *Physis: Revista de Saúde Coletiva*, 27(01), 127-146.
- [64] Skalfist, P. (2019). A revolução robótica (Vol. 2). Livros de Cambridge Stanford.
- [65] Sonia, J. J., Jayachandran, P., Md, A. Q., Mohan, S., Sivaraman, A. K., & Tee, K. F. (2023). Machine-learning-based diabetes mellitus risk prediction using multi-layer neural network no-prop algorithm. *Diagnostics*, 13(4), 723.

- [66] Souza, R. V. D. (2023). Implementação de um modelo baseado em visão computacional para detecção de retinopatia diabética em imagens de fundo de olho.
- [67] Sun, H., Saeedi, P., Karuranga, S., Pinkepank, M., Ogurtsova, K., Duncan, B. B., ... & Magliano, D. J. (2022). IDF Diabetes Atlas: Global, regional, and country-level diabetes prevalence estimates for 2021 and projections for 2045. *Diabetes research and clinical practice*, 183, 109119.
- [68] Vieira, J. P., Parreira, F. J., & Silveira, S. R. (2016). Desenvolvimento de um Sistema para Auxílio ao Diagnóstico de Diabetes empregando Redes Neurais Artificiais (SADD). *Revista de Sistemas e Computação-RSC*, 6(1).
- [69] Zapelini, R. M., Martinelli, M. T., João, R. M., & Iser, B. P. M. (2015). Critérios diagnósticos e prevalência de Diabetes Mellitus Gestacional em um hospital do sul de Santa Catarina. *Revista da AMRIGS [Internet]*, 177-81.
- [70] Zuccolotto, D. C. C., Crivellenti, L. C., Franco, L. J., & Sartorelli, D. S. (2019). Padrões alimentares de gestantes, excesso de peso materno e diabetes gestacional. *Revista de saúde pública*, 53, 52.

## Apêndice A: Questionários

Durante a pesquisa da dissertação, desenvolveu-se um questionário que tem como objetivo coletar informações sobre a prevalência, fatores de risco e gestão do diabetes na cidade da Covilhã. Com objetivo de criar uma rede neuronal artificial capaz de prever o risco de diabetes com base nos fatores multidimensionais. As suas respostas são importantes para a pesquisa.

As informações recolhidas serão confidenciais e exclusivas para uso académico.

### 1) Idade:

- Menos de 18 anos
- 18-30 anos
- 31-45 anos
- 46-60 anos
- Mais de 60 anos

### 2) Sexo:

- Masculino
- Feminino
- Prefiro não dizer

### 3) Localização:

- Covilhã (Centro)
- Covilhã (Outros bairros)
- Outras Localidades

### 4) Estado Civil:

- Solteiro(a)
- Casado(a)
- Divorciado(a)
- Viúvo(a)

5) Altura: \_\_\_\_\_ m

6) Peso: \_\_\_\_\_ kg

### 7) Medida da cintura:

**Se for homem:**  menos que 94 cm  entre 94 e 102 cm  mais que 102 cm

**Se for mulher:**  menos que 80 cm  entre 80 e 88 cm  mais que 88 cm

### 8) Realiza atividade física regularmente?

- Não
- Sim, até 30 minutos por dia ou menos de 4 horas por semana
- Sim, mais de 30 minutos por dia ou mais de 4 horas por semana

**9) Consome diariamente frituras, salgados ou carnes gordas (incluindo frango com pele)?**

Sim

Não

**10) Consome diariamente vegetais, frutas, legumes ou grãos?**

Sim

Não

**11) Fuma?**

Não, nunca fumei

Fumo 1 a 10 cigarros por dia

Fumava mas parei

Fumo mais que 10 cigarros por dia

**12) Se fuma, desde quando começou a fumar regularmente?**

Menos de 1 ano

1 a 5 anos

6 A 10 anos

11 a 20 anos

Mais de 21 anos

**13) Alguma vez teve alterações do seu nível de glicose?**

Sim

Não

**14) Se é mulher e já esteve grávida, alguma vez teve alteração do seu nível de glicose ou diabetes durante a gravidez?**

Sim

Não

**15) Tem pressão alta ou toma remédios para controlá-la?**

Sim

Não

**16) Qual a faixa de pressão arterial que melhor descreve sua condição atual?**

Abaixo de 120/80 mmHg

120-139/80-89 mmHg

140-159/90-99 mmHg

160/100 mmHg ou superior

180/120 mmHg ou superior

**17) Tem parentes em primeiro grau (pais, irmãos e filhos) com diabetes?**

Sim

Não

**18) Tem parentes em segundo grau (avós, tios e primos em primeiro grau) com diabetes?**

Sim

Não

**19) Foi diagnosticado com diabetes?**

Sim

Não

**20) Se sim, qual tipo de diabetes possui?**

Tipo 1

Tipo 2

Outro

**21) Qual faixa de rendimento salarial melhor descreve sua situação financeira?**

Menos de 500 euros por mês

500 a 1000 euros por mês

1001 a 2500 euros por mês

Mais de 2500 euros por mês

**22) Há algo mais que gostaria de compartilhar sobre sua experiência com a diabetes?**

---

# Apêndice B: Tabela de treinamento

Tabela apêndice B-1 Treinamento e Indivíduos em falhas.

Run 1		Run 2	
76.1905	8 10 11 14 17	76.1905	8 11 12 17 18
76.1905	8 11 12 17 20	61.9048	6 8 9 10 11 12 13 19
61.9048	4 8 9 11 15 17 18 20	85.7143	6 8 11
76.1905	1 8 11 12 14	71.4286	1 8 9 11 12 13
80.9524	5 10 11 17	76.1905	8 11 12 13 14
71.43	6 8 9 11 17 19	61.90	8 9 11 12 14 15 17 20
66.6667	4 5 8 9 11 12 20	66.6667	8 9 11 12 15 16 19
76.1905	6 8 11 20 21	66.6667	1 4 6 8 11 13 17
57.1429	4 5 8 9 11 12 13 20 21	76.1905	1 8 11 14 18
66.6667	5 6 8 9 11 17 20	71.4286	11 14 15 16 17 19
80.9524	8 9 10 14	71.4286	5 6 10 11 14 15
95.2381	10	76.1905	5 11 12 13 15
76.1905	8 11 14 15 17	52.381	1 5 6 8 9 10 11 13 17 20
76.1905	8 9 12 13 20	66.6667	4 5 11 12 13 15 17
80.9524	8 10 11 15	76.1905	4 5 8 11 13
85.7143	8 11 12	80.9524	8 11 13 20
80.9524	1 8 11 14	76.1905	8 10 11 14 17
61.9048	5 6 8 10 11 12 16 17	80.9524	8 11 17 19
Run 3		Run 4	
66.6667	6 8 11 12 14 17 19	66.6667	8 10 11 13 14 16 17
66.6667	8 10 11 14 16 17 19	85.7143	8 10 20
85.7143	4 9 11	71.4286	1 8 9 10 11 20
80.9524	6 8 11 14	85.7143	8 11 13
90.4762	8 20	52.381	6 8 9 11 12 14 17 19 20 21
80.95	8 11 17 20	90.47	8 12
57.1429	1 5 9 10 13 14 15 17 20	85.71	8 11 12
66.6667	5 9 11 12 15 18 20	61.90	5 6 8 9 11 12 13 20
71.4286	5 11 12 13 14 17	80.95	5 8 10 13
66.6667	1 5 6 9 11 12 13	85.71	5 11 14
80.9524	10 11 14 17	80.95	8 11 13 20
76.1905	5 12 14 17 20	80.95	5 10 13 17
80.9524	5 10 13 17	76.19	8 9 11 14 17
80.9524	8 9 11 13	76.19	8 9 10 17 19
76.1905	8 9 13 16 17	76.19	8 10 11 13 14
61.9048	6 8 10 11 14 17 19 21	90.48	8 10
71.4286	1 5 8 11 14 17	76.19	4 8 11 14 17
71.4286	1 5 9 10 13 14	80.95	4 6 8 13
Run 5		Run 6	
80.9524	1 8 11 21	76.1905	8 10 11 16 19
71.4286	8 9 11 12 14 17	80.9524	1 8 10 11

66.6667	1 5 6 8 11 13 17	85.7143	8 11 20
71.4286	6 8 11 12 14 20	85.7143	8 11 17
76.1905	4 8 11 12 13	76.1905	1 8 12 13 20
80.95	1 8 10 11	76.19	5 6 8 10 13
80.9524	4 8 11 12	76.1905	8 11 12 20 21
71.4286	5 8 10 14 17 21	71.4286	5 12 13 14 17 20
76.1905	5 8 9 11 14	85.7143	8 11 12
71.4286	8 9 11 12 14 19	71.4286	6 8 10 11 15 19
85.7143	8 11 13	80.9524	6 8 10 11
47.619	6 8 9 10 12 13 14 15 16 17	76.1905	8 9 10 11 13
71.4286	8 10 11 13 14 20	85.7143	8 10 14
80.9524	5 8 11 16	80.9524	8 11 14 20
71.4286	5 9 10 11 14 17	76.1905	8 10 11 14 17
76.1905	2 8 10 15 18	66.6667	8 9 11 12 14 17 19
90.4762	8 11	85.7143	8 11 12
61.9048	4 6 8 9 11 12 15 19	66.6667	8 9 10 11 14 17 19
<b>Run 7</b>		<b>Run 8</b>	
80.9524	8 9 13 17	66.6667	8 9 10 11 13 17 19
76.1905	1 8 11 12 17	85.7143	8 11 12
76.1905	1 8 11 12 14	66.6667	6 8 9 11 14 16 17
85.7143	8 11 12	90.4762	10 17
57.1429	6 8 9 11 12 15 17 19 21	71.4286	8 11 12 16 19 20
61.90	6 8 10 11 13 14 17 20	76.19	9 10 11 17 19
71.4286	4 11 12 13 16 17	66.6667	8 9 11 12 13 17 19
90.4762	11 12	85.7143	8 10 11
71.4286	8 10 11 17 18 21	80.9524	8 9 11 12
80.9524	4 5 8 14	66.6667	1 5 7 10 13 16 17
80.9524	8 11 14 17	71.4286	6 8 11 14 15 17
85.7143	5 16 20	57.1429	5 6 9 11 12 13 16 17 19
80.9524	8 11 12 20	71.4286	5 6 10 11 12 13
76.1905	1 4 5 11 14	76.1905	8 9 11 14 20
80.9524	8 11 14 19	90.4762	8 10
66.6667	8 9 11 12 14 17 19	85.7143	8 11 18
66.6667	8 11 12 13 15 17 20	76.1905	8 11 12 14 19
76.1905	5 10 13 14 16	76.1905	8 11 12 14 19
<b>Run 9</b>		<b>Run 10</b>	
66.6667	4 5 6 8 11 13 17	80.9524	8 11 12 14
57.1429	4 6 9 11 14 15 17 20 21	76.1905	6 8 11 12 17
76.1905	4 8 11 12 21	76.1905	8 10 11 14 17
85.7143	8 10 17	71.4286	6 8 10 11 13 20
85.7143	8 11 14	71.4286	8 10 11 15 17 20
71.43	8 11 15 17 20 21	76.19	6 8 11 13 14
80.9524	8 9 11 19	71.4286	1 5 8 11 12 20
57.1429	5 9 10 13 15 16 17 19 20	71.4286	8 11 12 13 17 19

80.9524	6 9 10 17	76.1905	1 10 12 14 17
80.9524	5 13 17 20	71.4286	1 6 8 11 12 19
90.4762	8 10	85.7143	5 8 11
85.7143	8 11 14	76.1905	6 8 10 11 14
57.1429	6 8 9 10 11 12 13 17 19	80.9524	10 13 14 17
76.1905	8 12 14 17 19	90.4762	1 10
85.7143	11 12 20	57.1429	1 4 6 8 9 11 14 16 17
80.9524	11 13 15 17	66.6667	4 9 11 12 14 17 19
85.7143	11 12 14	85.7143	8 10 11
76.1905	11 14 15 20 21	76.1905	6 8 10 14 17
<b>Run 11</b>		<b>Run 12</b>	
90.4762	8 11	85.7143	6 8 11
85.7143	4 8 11	76.1905	8 10 11 14 17
61.9048	6 8 10 11 13 14 20 21	80.9524	6 8 11 13
80.9524	8 11 12 13	85.7143	8 10 11
80.9524	8 9 11 12	80.9524	8 11 13 20
76.19	8 9 11 12 14	76.19	1 6 8 10 17
76.1905	5 9 10 17 20	80.9524	1 8 10 11
80.9524	6 8 11 13	76.1905	4 9 11 12 16
71.4286	5 8 11 13 20 21	80.9524	8 10 13 17
66.6667	8 9 11 12 15 17 21	71.4286	7 8 9 12 13 20
66.6667	5 10 13 14 15 16 17	66.6667	6 8 12 13 15 16 17
76.1905	8 10 11 17 19	76.1905	5 8 10 13 20
66.6667	1 8 11 13 15 17 20	85.7143	8 10 11
71.4286	4 8 10 11 12 19	80.9524	1 8 11 20
76.1905	1 8 10 14 17	71.4286	6 8 10 13 16 19
85.7143	8 10 11	80.9524	8 11 14 20
71.4286	8 10 11 13 14 17	66.6667	6 9 10 11 13 14 17
80.9524	8 10 11 13	76.1905	8 9 10 13 14
<b>Run 13</b>		<b>Run 14</b>	
76.1905	8 10 11 13 17	71.4286	8 10 11 12 14 17
90.4762	11 20	85.7143	8 10 20
66.6667	4 8 9 11 12 14 17	80.9524	6 8 9 11
80.9524	8 11 12 13	66.6667	8 9 11 12 14 17 19
80.9524	8 10 11 20	80.9524	6 8 11 14
90.48	10 13	76.19	6 8 11 19 21
80.9524	5 11 13 15	80.9524	5 11 12 20
66.6667	1 4 8 11 16 17 20	71.4286	1 8 11 12 14 20
71.4286	4 6 11 12 15 19	71.4286	1 5 8 11 17 19
71.4286	6 8 11 12 13 16	71.4286	4 5 10 11 17 18
57.1429	6 8 9 10 13 15 17 19 20	76.1905	6 8 10 11 13
66.6667	5 6 8 10 11 15 17	85.7143	8 11 14
80.9524	8 10 11 14	76.1905	5 6 10 13 19
85.7143	8 11 12	66.6667	8 10 11 13 14 17 20
90.4762	11 20	80.9524	8 11 13 14
80.9524	8 10 11 20	85.7143	8 10 14
85.7143	8 11 17	71.4286	8 10 11 12 14 17

85.7143	8 11 12	76.1905	6 8 10 11 12
<b>Run 15</b>			
90.4762	8 11		
61.9048	1 2 8 11 13 17 20 21		
71.4286	6 11 12 14 15 17		
76.1905	5 6 11 13 19		
66.6667	8 12 14 15 17 20 21		
71.43	6 8 11 12 14 17		
85.714	8 10 20		
90.4762	10 11		
76.1905	5 10 13 14 16		
71.4286	8 10 14 15 17 19		
76.1905	1 8 10 11 13		
76.1905	8 11 12 14 17		
57.1429	5 11 12 13 14 15 16 17 19		
66.6667	4 8 9 11 12 14 20		
71.4286	4 11 12 16 17 19		
90.4762	8 11		
80.9524	8 9 11 17		
76.1905	8 10 11 19 20		