

**UNIVERSIDADE FEDERAL DE SANTA CATARINA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA
COMPUTAÇÃO**

ALDIR ROBERTO PEROZIN

**INTELIGÊNCIA COMPUTACIONAL AVALIANDO
RISCO CORONARIANO**

Dissertação submetida à Universidade Federal de Santa Catarina como parte dos requisitos para a obtenção do grau de Mestre em Ciência da Computação

**Prof. José Mazucco Junior, Dr.
Orientador**

Florianópolis, Maio de 2002.

INTELIGÊNCIA COMPUTACIONAL AVALIANDO RISCO CORONARIANO

ALDIR ROBERTO PEROZIN

Esta Dissertação foi julgada adequada para a obtenção do título de Mestre em Ciência da Computação Área de Concentração Sistemas de Conhecimento e aprovada em sua forma final pelo Programa de Pós-Graduação em Ciência da Computação.

Banca Examinadora

Fernando A. Ostuni Gauthier, Dr.
Coordenador do Curso

José Mazzucco Junior, Dr. (Presidente)

Paulo Sérgio da Silva Borges, Dr.

Luiz Fernando Jacintho Maia, Dr.

Carmen Dolores de Araújo Waltrick

O mérito de fazer o bem está na dificuldade de praticá-lo;
Não há mérito em fazer o bem sem esforço e quando não custa nada.
Deus tem mais em conta o pobre que partilha seu único pedaço de pão,
do que o rico que dá apenas o supérfluo.
(Allan Kardec - O Livro dos Espíritos)

AGRADECIMENTOS

A DEUS, que é a inteligência suprema,
é eterno, imutável, imaterial, único, todo-poderoso,
soberanamente justo e bom.

À Sonia, Melissa e Etiane Perozin,
pelo carinho, incentivo, compreensão e apoio,
pelas horas que passei em frente ao computador,
quando poderia estar mais próximo a vocês,
pela falta de tempo, diálogo e atenção a vocês,
por todo o tempo de ausência.

Ao Adair José Perozin e Nara Regina Perozin,
pelo incentivo, acolhida e apoio em Florianópolis.

Ao Dr. Carlos Tochio Mori,
Ao Dr. Bernardo Augusto Günther,
Ao Pedro Silvano Günther,
À Hotsf Informática, pelo banco de dados,
pelo incentivo, apoio e informações.

Ao Prof. José Mazzucco Junior, Dr.
pelo incentivo e apoio nas horas difíceis,
pela sua orientação e sua amizade.

Ao Prof. Jovelino Falqueto, Dr.
pelo apoio valioso recebido.

À Dra. Carmen Dolores de Araújo Waltrick,
por todo apoio material e informações,
muito importante para o êxito deste trabalho.

Aos profissionais do NIPEAD/HU/UFSC,
pelo apoio e informações (dados utilizados no trabalho).

À Sílvia Helena,
pelo seu incentivo e apoio,
pelo seu carinho e sua amizade.

A todas as pessoas que de forma direta ou indireta,
contribuíram para o êxito de mais essa etapa de aprendizado,
e para o crescimento espiritual, pessoal e profissional.

Em memória de meus pais Antonio e Thereza Bósio Perozin,
e irmãos Salete Perozin Treméa e Jorge Luiz Perozin.

RESUMO

Neste trabalho foi explorada a potencialidade das Redes Neurais no estudo de fatores de risco de doenças arteriais coronarianas. Na sua forma mais geral, uma *rede neural*, é uma máquina que é projetada para *modelar* a maneira como o cérebro realiza uma tarefa particular ou função de interesse, através da sua propriedade de “aprender” a partir de um conjunto de dados de entrada. O procedimento utilizado para realizar o processo de aprendizagem é chamado de *algoritmo de aprendizagem*. Para alcançarem bom desempenho, as redes neurais empregam uma interligação maciça de células computacionais simples denominadas “neurônios” ou “unidades de processamento”.

Apesar de estarmos numa época de tecnologia e de avanços em estudos e diagnósticos em relação à doença arterial coronária, a realidade é que tal patologia ainda representa a principal causa de mortalidade e morbidade no mundo ocidental.

Neste trabalho aplicando a Teoria dos Fuzzy Sets (*Conjuntos Difusos* ou *Nebulosos*) aos princípios da lógica clássica e resultados da rede neural sobre o conjunto de dados de treinamento, foi possível determinar um valor percentual pertinente ao grau de risco de doença coronária de cada indivíduo ponderando-se dados clínicos e laboratoriais pré-existentes.

ABSTRACT

In this research was also explored the potentiality of the *neural networks* on the study of the factors of risk on coronary arterial disease. In the most general way, a neural network is a machine designed to model how the brain will perform one particular task or function of interest, due to its property of "learning" from a given input. The procedure used to perform learning process is called learning algorithm. In order to reach good performance, the neural networks employ a massive interface of simple cells, called "neurons" or "processing units".

Despite we live a technological and progressive era about the study and diagnosis of coronary arterial diseases, the reality shows that such pathology remains representative as the main cause of mortality on the western world.

In this study case, due to the employment of the Fuzzy Sets Theory (Diffuse or Misty groups) to the principles of the classic logic and results of the Neural networks on the mapped data, it was possible to determine a percentage value to the risk band of each individual about coronary diseases, regarding medical and laboratorial backgrounds.

SUMÁRIO

PÁGINA DE APROVAÇÃO.....	ii
EPÍGRAFE.....	iii
AGRADECIMENTOS.....	iv
RESUMO.....	v
ABSTRACT.....	vi
SUMÁRIO.....	vii
LISTA DE SIGLAS.....	x
LISTA DE TABELAS.....	xi
LISTA DE FIGURAS.....	xii
LISTA DE GRÁFICOS.....	xiii
INTRODUÇÃO	14
1.1 OBJETIVOS DO TRABALHO.....	15
1.2 ORGANIZAÇÃO.....	15
2 REDES NEURAI	16
2.1 O QUE É UMA REDE NEURAL.....	16
2.1.1 BENEFÍCIOS DAS REDES NEURAI.....	17
2.2 O CÉREBRO HUMANO.....	18
2.3 MODELOS DE UM NEURÔNIO.....	19
2.4 ARQUITETURA DE REDE.....	20
2.5 REPRESENTAÇÃO DO CONHECIMENTO.....	23
2.6 INTELIGÊNCIA ARTIFICIAL E REDES NEURAI.....	26
2.7 PROCESSOS DE APRENDIZAGEM	29
2.8 APRENDIZAGEM POR CORREÇÃO DE ERRO.....	30
2.9 APRENDIZAGEM BASEADA EM MEMÓRIA.....	31
2.10 APRENDIZAGEM HEBBIANA.....	32
2.11 APRENDIZAGEM COMPETITIVA	33
2.12 APRENDIZAGEM DE BOLTZMANN.....	34
2.13 APRENDIZAGEM SUPERVISIONADA.....	34
2.14 APRENDIZAGEM NÃO SUPERVISIONADA.....	36
2.15 TAREFAS DE APRENDIZAGEM	37
2.15.1 ASSOCIAÇÃO DE PADRÕES	38
2.15.2 RECONHECIMENTO DE PADRÕES.....	38
2.15.3 APROXIMAÇÃO DE FUNÇÕES.....	39
2.15.4 CONTROLE.....	39
2.15.5 FILTRAGEM	40
2.15.6 FORMAÇÃO DE FEIXE.....	41
2.16 MEMÓRIA.....	42
2.17 RESUMO DO PROCESSO DE APRENDIZAGEM	45
2.18 PERCEPTRON DE CAMADA ÚNICA.....	46
2.19 PERCEPTRON DE MÚLTIPLAS CAMADAS	47
2.20 O PROBLEMA DA FILTRAGEM ADAPTATIVA.....	49
2.21 O PERCEPTRON.....	51
2.22 SOFTWARE MODELADOR DE REDES NEURAI PYTHIA	54

3	FATORES DE RISCO PARA DOENÇA ARTERIAL CORONARIANA	58
3.1	FATORES DE RISCO (FR).....	58
3.2	DOENÇA ARTERIAL CORONARIANA (DAC).....	60
3.2.1	ARTERIOSCLEROSE.....	60
3.2.2	ATEROSCLEROSE.....	60
3.2.3	ISQUEMIA.....	61
3.3	CLASSIFICAÇÃO DOS FATORES DE RISCO PARA DAC.....	62
3.3.1	DISLIPIDEMIA.....	62
3.3.1.1	CLASSIFICAÇÃO DAS DISLIPIDEMIAS.....	63
3.3.1.2	CLASSIFICAÇÃO ETIOLÓGICA.....	64
3.3.1.3	PERFIL LIPÍDICO.....	64
3.3.1.4	RESULTADOS NORMAIS.....	65
3.3.1.5	INTERPRETAÇÃO DAS ANOMALIAS DO LIPIDROGRAMA.....	67
3.3.1.6	COLESTEROL.....	68
3.3.1.7	CORRELAÇÃO ENTRE HIPERLIPIDEMIA E DAC.....	68
3.3.2	TABAGISMO.....	70
3.3.3	DIABETES.....	70
3.3.4	OBESIDADE.....	71
3.3.4.1	IMC.....	71
3.3.4.2	ÍNDICE DE RELAÇÃO DE GORDURA ENTRE CIRCUNFERÊNCIA DO ABDÔMEN E QUADRIL – WHR.....	72
3.3.5	HIPERTENSÃO ARTERIAL SISTÊMICA.....	73
3.3.6	ÁCIDO ASCÓRBICO E DOENÇAS CARDIOVASCULARES.....	75
3.3.7	SEDENTARISMO.....	75
3.4	PREVENÇÃO.....	76
3.5	DIAGRAMA DE AVALIAÇÃO DE RISCO CORONARIANO.....	77
4	MÉTODOS E PROCEDIMENTOS UTILIZADOS NO ESTUDO	80
4.1	RESULTADOS LIPIDICOS PARA AVALIAÇÃO DE RISCO CORONARIANO.....	80
4.1.1	CRIANDO UM BANCO DE DADOS PADRÃO XBASE.....	81
4.1.2	PRIMEIRA ANÁLISE DOS DADOS.....	82
4.1.3	FUNÇÃO PARA CLASSIFICAÇÃO DA AVALIAÇÃO DE RDC.....	83
4.1.3.1	RESULTADO DA FUNÇÃO DE CLASSIFICAÇÃO DE RDC.....	83
4.1.3.2	DETERMINAÇÃO FUNÇÃO LOGÍSTICA OU SIGMÓIDE PARA CÁLCULO DE RDC.....	84
4.1.3.3	FUNÇÃO LOGÍSTICA OU SIGMÓIDE PARA CÁLCULO DO RDC ..	86
4.1.4	SUBMETENDO OS RESULTADOS DA FUNÇÃO A ANÁLISE DE UM PROFISSIONAL.....	87
4.1.4.1	CONSULTA MÉDICA OU CONSULTA TÉCNICA ?.....	87
4.2	NOVOS DADOS DE AMOSTRA UTILIZADOS NO ESTUDO.....	88
4.2.1	TÓPICOS DA INFORMAÇÕES CONTIDAS NO FORMULÁRIO DE AVALIAÇÃO DE CADA INDIVÍDUO DO ESTUDO.....	89
4.2.2	MÉTODOS E PROCEDIMENTOS UTILIZADOS NA ANÁLISE DE RESULTADOS DA COLETA.....	90
4.2.3	CLASSIFICAÇÃO DOS DADOS DA AMOSTRA.....	91
4.2.4	ALTERAÇÕES NA TABELA DE CLASSIFICAÇÃO DOS DADOS DA AMOSTRA.....	92
4.2.5	CLASSIFICAÇÃO DE AVALIAÇÃO DOS RISCOS DE DOENÇA.....	92

4.3	PROCESSO DE AVALIAÇÃO DE ÍNDICES E RISCOS.....	94
4.3.1	MÓDULOS DO PROJETO DO SOFTWARE DESENVOLVIDO.....	94
4.3.2	CONVERSÃO DA TABELA DE AVALIAÇÃO DE RDC.....	96
4.3.3	TELA DE CADASTRO COM AVALIAÇÃO DE RISCO.....	97
4.4	ANÁLISE ESTATÍSTICA DOS RESULTADOS.....	98
4.4.1	QUANTIFICAÇÃO DOS DADOS.....	98
4.4.2	DISTRIBUIÇÃO DOS DADOS POR FAIXA ETÁRIA E QUANTIFICAÇÃO PELA CLASSIFICAÇÃO DOS DADOS.....	100
4.4.3	REPRESENTAÇÃO GRÁFICA DOS DADOS DA AMOSTRA.....	104
4.5	ANÁLISE DO CONJUNTO DE DADOS DA AMOSTRA COM ALGORITMO DE RETROPROPAGAÇÃO NA REDE NEURAL.....	107
4.5.1	APRESENTANDO OS DADOS A REDE NEURAL.....	107
4.5.2	CRIANDO MODELO DA REDE NEURAL.....	109
4.5.3	O APRENDIZADO DA REDE NEURAL.....	111
4.5.4	OTIMIZAÇÃO EVOLUCIONÁRIA DO MODELO DA REDE NEURAL....	114
4.5.5	TESTANDO A REDE NEURAL COM UM ÚNICO CONJUNTO DE DADOS	115
4.5.6	CONJUNTO DE DADOS DE TREINAMENTO E TESTE	116
4.5.7	RESULTADOS DOS ESTUDOS COM A REDE NEURAL.....	117
4.5.8	GRÁFICO DE REGRESSÃO LINEAR DO MELHOR ESTUDO.....	119
4.5.9	COMPARATIVO RISCO RDC E RESULTADO OBTIDO PELA REDE.....	120
4.6	DEFUZZIFICAÇÃO DO RISCO DE DOENÇA CORONARIANA.....	120
4.6.1	SOFTWARE DE LÓGICA FUZZY.....	123
4.6.2	SCRIPT RESULTANTE DA UTILIZAÇÃO DO SOFTWARE FUDGE.....	124
5	CONCLUSÃO E CONSIDERAÇÕES FINAIS	127
5.1	SUGESTÕES PARA OUTROS TRABALHOS.....	130
6	REFERENCIAS BIBLIOGRÁFICAS	131
ANEXOS		
	ANEXO 1.....	136
	ANEXO 2	138
	ANEXO 3.....	140
	ANEXO 4.....	142
	ANEXO 5.....	144
	ANEXO 6.....	145
	ANEXO 7.....	147
	ANEXO 8.....	150
	ANEXO 9.....	154
	ANEXO 10.....	158

LISTA DE SIGLAS

SIGLA	DESCRIÇÃO
AHA	American Heart Association
AVC	acidente vascular cerebral
BP	Retropropagação (<i>back-propagation</i>)
CC	medida da circunferência da cintura
CLLG	cancelador de lóbulo lateral generalizado
CQ	medida da circunferência do quadril
CT	colesterol total
DAC	doença arterial coronariana
DM	diabete melito
ECG	eletrocardiograma (<i>exame das ondas elétricas do coração</i>)
ERF	estudo de risco de Framingham
EST	estatura (<i>altura</i>)
EUA	Estados Unidos da América
FC	frequência cardíaca
FR	fator de risco
FST	teoria dos Fuzzy sets (<i>conjuntos difusos ou nebulosos</i>)
HAS	Hipertensão arterial sistêmica
HDL-c	lipoproteínas de alta densidade (<i>high-density lipoproteins</i>)
HU	Hospital Universitário da Universidade Federal de Santa Catarina-UFSC
IA	Inteligência artificial
IAM	infarto agudo do miocárdio
ICQ	índice cintura quadril ou índice abdominal
IMC	índice de massa corporal (<i>índice de Quetelet</i>)
LDL-c	lipoproteínas de baixa densidade (<i>low-density lipoproteins</i>)
LMS	algoritmo do mínimo quadrado médio (<i>least-mean-square</i>)
MC	massa corporal
MEV	mudança do estilo de vida
NIPEAD	Núcleo Interdisciplinar de Pesquisa, Ensino e Assistência à Dislipidemia
OMS	Organização Mundial de Saúde
PA	pressão arterial
PAD	pressão arterial diastólica
PAS	pressão arterial sistólica
RCQ	RISCO CINTURA QUADRIL OU RISCO ABDOMINAL
RDC	risco doença coronariana
RMC	risco massa corporal
SASC	Serviço de Atendimento de Saúde à Comunidade Universitária
TG	Triglicérides (<i>triglicerídios</i>)
UFSC	Universidade Federal de Santa Catarina
VLDL	Lipoproteínas de muito baixa densidade (<i>very-low-density lipoproteins</i>)
WHR	índice de relação de gordura entre circunferências do abdômen e quadril (<i>waist-hip ratio</i>)

LISTA DE TABELAS

3.1	níveis de risco e percentuais de possibilidade de ocorrência dos FR.....	59
3.2	tabela de índice de óbitos no Brasil por região de doenças coronárias.....	61
3.3	valores de referência dos lipídios para indivíduos > 20 anos de idade.....	64
3.4	teor de lipídios no plasma (EUA)(mg/100ml).....	66
3.5	teores plasmáticos normais das diversas frações lipídicas.....	66
3.6	teores normais de colesterol hdl - (<i>lipid research clinic</i> – EUA).....	66
3.7	colesterol hdl e risco de cardiopatia isquêmica.....	69
3.8	relação colesterol total/colesterol hdl e risco de cardiopatia isquêmica.....	69
3.9	critérios diagnósticos da American Diabetes Association 1997.....	71
3.10	classificação da obesidade com base no IMC correlacionada com o risco.....	72
3.11	tabela para zona de risco associada com o WHR.....	73
3.12	classificação da hipertensão arterial sistêmica.....	74
3.13	distribuição dos valores de referência por faixa na avaliação de fator RDC.....	77
3.14	diagrama para avaliação do risco coronariano na prevenção primária da DAC...	79
4.1	amostra do arquivo dos resultados para avaliação de lipidograma.....	81
4.2	estrutura do arquivo banco de dados criado para análise de lipidograma.....	81
4.3	resultados não classificados pela função de classificação da avaliação de risco...	84
4.4	resultados da função logística ou sigmóide aplicada sobre resultados de CT.....	85
4.5	valores originais e da função logística sobre os resultados lipídicos.....	86
4.6	valores de referência da tabela originalmente tabulada.....	91
4.7	valores de referência da tabela atualizada.....	93
4.8	tabela de riscos de DAC combinados no banco de dados.....	97
4.9	estatísticas básicas dos resultados e avaliação de risco.....	100
4.10	quantificação geral por faixa etária dos FR e riscos.....	101
4.11	percentuais gerais por faixa etária dos FR e riscos.....	101
4.12	percentuais gerais por faixa etária das avaliações de risco.....	101
4.13	quantificação da amostra feminina por faixa etária, FR e riscos.....	102
4.14	percentuais da amostra feminina por faixa etária dos fatores de riscos.....	102
4.15	percentuais da amostra feminina por faixa etária e avaliações de risco.....	102
4.16	quantificação da amostra masculina por faixa etária, FR e riscos.....	103
4.17	percentuais da amostra masculina por faixa etária e fatores de risco.....	103
4.18	percentuais da amostra masculina por faixa etária das avaliações de risco.....	103
4.19	conjunto de dados apresentados para treinamento da rede neural.....	107
4.20	resultados do dados apresentados para treinamento e teste.....	116
4.21	resultados dos estudos com conjunto de dados de treinamento.....	117
4.22	grau de avaliação de DAC.....	121
4.23	conjunto de dados de treinamento com RDC avaliado pelo método tradicional..	121
4.24	alteração do RDC para saída de acordo com o grau.....	121
4.25	conjunto de dados de treinamento com RDC modificado.....	122
4.26	variáveis de RDC calculadas pela rede neural.....	122
4.27	valores calculados pela rede multiplicados pelo grau do RDC.....	122
4.28	Valores calculados pela rede e o percentual de RDC.....	123

LISTA DE FIGURAS

2.1	representação em diagrama em blocos do sistema nervoso.....	18
2.2	modelo não-linear de um neurônio.....	19
2.3	rede alimentada adiante ou acíclica com uma única camada de neurônios.....	21
2.4	rede alimentada adiante ou acíclica totalmente conectada com uma camada oculta e uma camada de saída.....	22
2.5	rede recorrente sem laços de auto-realimentação e sem neurônios ocultos.....	23
2.6	rede recorrente com neurônios ocultos.....	23
2.7	ilustração dos três componentes principais de um sistema de IA.....	26
2.8	modelo simples de aprendizagem de máquina.....	28
2.9	ilustração da aprendizagem por correção de erro.....	30
2.10	diagrama em blocos da aprendizagem supervisionada.....	35
2.11	diagrama em blocos da aprendizagem por esforço.....	36
2.12	diagrama em blocos da aprendizagem não-supervisionada.....	37
2.13	diagrama em blocos de um sistema de controle realimentado.....	40
2.14	diagrama em blocos do cancelador de lóbulo lateral generalizado.....	42
2.15	modelo de memória associativa utilizando neurônios artificiais.....	44
2.16	grafo de fluxo de sinal do modelo adaptativo para o sistema.....	50
2.17	grafo de fluxo de sinal do perceptron.....	51
2.18	ilustração do hiperplano como fronteira de decisão para um problema de classificação de padrões bidimensional de duas classes.....	53
2.19	representação de uma típica rede back-propagation.....	54
2.20	janela para normalização dos dados de entrada e saída.....	56
2.21	tela da entrada manual de dados para teste.....	56
2.22	resultado da entrada manual de dados.....	57
4.1	função logística sigmóide para avaliação de risco CT, LDL e TG.....	85
4.2	função logística sigmóide para da avaliação de risco HDL.....	85
4.3	tela de entrada de dados com o resultado da avaliação de risco.....	98
4.4	importação de dados da área de transferência.....	108
4.5	tabela do conjunto de dados já importados.....	108
4.6	normalização do conjunto de dados.....	109
4.7	definindo a quantidade de neurônios da rede neural.....	110
4.8	modelo da rede neural de retropropagação (<i>back-propagation</i>).....	111
4.9	determinação do modo de treinamento para o conjunto de dados.....	112
4.10	execução do modo de treinamento para o conjunto de dados.....	113
4.11	resultado do treinamento para o conjunto de dados.....	113
4.12	otimização evolucionária para o conjunto de dados.....	114
4.13	geração do otimização evolucionário para o conjunto teste.....	115
4.14	reprodução individual de dado para teste.....	116
4.15	resposta da reprodução individual de dado para teste.....	116
4.16	tabela de avaliação de pertinência do programa de lógica fuzzy.....	123
4.17	gráfico de pertinência do risco em relação ao percentual.....	127

LISTA DE GRÁFICOS

4.1	número dos dados da amostra geral e por sexo.....	99
4.2	percentual dos dados da amostra por sexo.....	99
4.3	percentual por risco coronariano.....	99
4.4	distribuição dos dados por faixa etária e sexo.....	99
4.5	indivíduos por sexo e classificação de diabetes.....	104
4.6	indivíduos por sexo e classificação por tabagismo.....	104
4.7	indivíduos por sexo e classificação por HAS.....	105
4.8	indivíduos por sexo e classificação por RCQ.....	105
4.9	indivíduos por sexo e classificação por RMC.....	106
4.10	indivíduos por sexo e classificação por RDC.....	106
4.11	regressão linear do resultado do estudo dois.....	119
4.12	gráfico comparativo do resultado do estudo 2.....	120

CAPÍTULO 1

INTRODUÇÃO

As *Redes Neurais* representam uma tecnologia que tem raízes em muitas disciplinas: *neurociência, matemática, estatística, física, ciência da computação e engenharia*. Sua propriedade de “aprender” a partir de um conjunto de dados de entrada faz com que sua aplicação se espalhe em diversos campos como modelagem, análise de series temporais, reconhecimento de padrões, processamento de sinais e controle, entre muitos outros.

De modo geral, o uso de redes neurais apresenta as seguintes vantagens:

- Não existe a determinação, a priori de quais fatores são determinantes sobre o modelo que está sendo desenvolvido;
- Permite a interferência de múltiplos fatores de entrada (ou seja, múltiplas variáveis), permitindo um inter-relacionamento muito mais complexo entre elas;
- A modelagem é feita diretamente no problema, sem a necessidade de se seguir um modelo preestabelecido, como no caso da regressão estatística;
- Apresenta paralelismo inerente: cada sinapse na rede neural pode ser seu próprio processador.

Neste trabalho foi explorada a potencialidade das Redes Neurais no estudo de *fatores de risco de doenças arteriais coronarianas*, especificamente, o perfil lipídico e a dislipidemia.

1.1 - OBJETIVOS DO TRABALHO

O objetivo central deste trabalho é demonstrar a potencialidade das redes Neurais na área médica. Com dados provenientes de resultados de exames de sangue (perfil lipídico), índice de massa corporal e antropométrico (índice relação cintura quadril), buscou-se desenvolver uma ferramenta básica que viesse a ser de grande utilidade a um profissional médico. Uma grande parte dessa dissertação envolveu estudos realizados junto a um núcleo de estudo sobre a *dislipidemia*, e *riscos coronários*. Foram pesquisados vários exames laboratoriais e fatores que influenciam nos seus resultados como: *idade*, *sexo*, *diabetes mellitus*, *hipertensão arterial*, *tabagismo* e outras variáveis que influenciam nos valores de resultados de cada paciente.

1.2 - ORGANIZAÇÃO DO TRABALHO

Esse trabalho está dividido em 5 capítulos organizados da seguinte forma:

- O capítulo 2 apresenta uma introdução a Redes Neurais e o software de Redes Neurais, utilizado neste estudo. Este capítulo foi baseado em grande parte no livro *Redes Neurais principio e prática* de Simon Haykin (2001).
- O capítulo 3 descreve a bioquímica do sangue humano, relacionando dislipidemia, seus riscos, causas e conseqüências das doenças coronarianas. Nesse capítulo também é tratado o levantamento e a organização dos dados, bem como os métodos laboratoriais utilizados.
- O emprego da rede neural propriamente dita é realizado no capítulo 4. Nele também são apresentados a parte estatística envolvida no trabalho, a análise dos resultados com os dados da amostra submetidos ao aprendizado e treinamento da rede neural.
- O capítulo 5 apresenta as considerações finais do trabalho e sugestões de continuidade do estudo e implementações possíveis a partir dos resultados obtidos.

CAPÍTULO 2

2.1 – O QUE É UMA REDE NEURAL

A era moderna das redes neurais começou com o trabalho pioneiro de Warren McCulloch e Walter Pitts (1943). McCulloch foi um psiquiatra e neuroanatomista que passou cerca de 20 anos refletindo sobre a representação de um evento no sistema nervoso. Pitts foi um prodígio matemático que se associou a McCulloch em 1942. De acordo com Rall (1990), o artigo de 1943 de McCulloch e Pitts surgiu dentro de uma comunidade de modelagem neural que tinha estado em atividade na University of Chicago por pelo menos cinco anos antes de 1943, sob a liderança de Rashevsky.

No seu clássico artigo, McCulloch e Pitts descreveram um cálculo lógico das redes neurais que unificava os estudos de neurofisiologia e da lógica matemática. Eles assumiam que o seu modelo formal de um neurônio seguia uma lei “tudo ou nada”. Com um número suficiente dessas unidades simples e com conexões sinápticas ajustadas apropriadamente e operando de forma síncrona, McCulloch e Pitts mostraram que uma rede assim constituída realizaria, a princípio, a computação de qualquer função computável.

O trabalho em redes neurais artificiais, usualmente denominadas “redes neurais”, tem sido motivado pelo reconhecimento de que o cérebro humano processa informações de uma forma inteiramente diferente do computador digital convencional. O cérebro é um *computador* (sistema de processamento de informação) altamente *complexo, não-linear, e paralelo*. Ele tem a capacidade de organizar seus constituintes estruturais, conhecidos por *neurônios*, de forma a realizar certos processamentos, por exemplo, reconhecimento de padrões, percepção e controle motor, muito mais rapidamente que o mais veloz computador digital hoje existente. Considere por exemplo, o *sonar* de um morcego. O sonar é um sistema ativo de localização por eco. Além de fornecer informações sobre a distancia até um alvo, transmite também

informações sobre a velocidade relativa, o tamanho, características, o azimute e a elevação do alvo (Suga, 1990a, b). A complexa computação neural necessária para extrair toda essa informação do eco do alvo ocorre no interior de um cérebro do tamanho de uma ameixa, (Haykin, 2001).

Na sua forma mais geral, uma *rede neural* é uma máquina que é projetada para *modelar* a maneira como o cérebro realiza uma tarefa particular ou função de interesse; a rede é normalmente implementada utilizando-se componentes eletrônicos ou é simulada por programação em um computador digital. Uma rede neural pode ser vista como uma máquina adaptativa:

Uma rede neural é um processador maciçamente paralelamente distribuído constituído de unidade de processamento simples, que tem a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso.

Ela se assemelha ao cérebro em dois aspectos:

1. *O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem.*
2. *Forças de conexão entre os neurônios, conhecidos como pesos sinápticos, são utilizados para armazenar o conhecimento adquirido.*

O procedimento utilizado para realizar o processo de aprendizagem é chamado de *algoritmo de aprendizagem*, sua função é modificar os pesos sinápticos da rede de uma forma ordenada para alcançar um objetivo de projeto desejado. (Haykin, 2001).

As redes neurais são também referenciadas na literatura como *neurocomputadores*, *redes conexionistas*, *processadores paralelamente distribuídos*, etc.

2.1.1 - BENEFÍCIOS DAS REDES NEURAIAS

Uma rede neural extrai seu poder computacional através de sua estrutura maciçamente paralelamente distribuída e de sua habilidade de aprender, portanto, de generalizar. A *generalização* se refere ao fato de que as redes neurais produzem saídas adequadas para entradas que não estavam presentes durante o treinamento (aprendizagem). Essas duas capacidades de processamento de informação permitem que

as redes neurais resolvam problemas complexos (de grande escala) que são muitas vezes considerados intratáveis.

2.2 – O CÉREBRO HUMANO

O sistema nervoso humano pode ser visto como um sistema de três estágios, como mostrado no diagrama em bloco da Fig.2.1 (Arbib, 1987). O centro do sistema é o *cérebro*, representado pela *rede neural (nervosa)*, que recebe continuamente informação, percebe-a e toma decisões apropriadas. Os *receptores* convertem estímulos do corpo humano ou do ambiente externo em impulsos elétricos que transmitem informação para a rede neural (cérebro). Os *atuadores* convertem impulsos elétricos gerados pela rede neural em respostas discerníveis como saídas do sistema.




FIGURA 2.1 Representação em diagrama em blocos do sistema nervoso

Foi o trabalho pioneiro de Ramón y Cajál (1911), que introduziu a idéia dos *neurônios* como constituintes estruturais do cérebro. Os neurônios são de cinco a seis ordens de grandeza mais lentos que as portas lógicas em silício; os eventos em um circuito de silício acontecem na ordem de nanossegundos (10^{-9} s), enquanto que eventos neurais acontecem na ordem de milissegundos (10^{-3} s). Entretanto, o cérebro compensa a taxa de operação relativamente lenta de um neurônio pelo número realmente espantoso de neurônios (células nervosas), com conexões maciças entre si. Estima-se que haja aproximadamente 10 bilhões de neurônios no córtex humano e 60 trilhões de sinapses ou conexões. O resultado é que o cérebro é uma estrutura extremamente eficiente.

As *sinapses* são unidades estruturais e funcionais elementares que medeiam as interações entre os neurônios.

Em um cérebro adulto a plasticidade, capacidade do sistema nervoso em desenvolvimento adaptar-se ao meio ambiente, pode ser atribuída a dois mecanismos: a criação de novas conexões sinápticas entre neurônios e a modificação das sinapses existentes.

Os neurônios artificiais que utilizamos para construir nossas redes neurais são realmente primitivos em comparação aos encontrados no cérebro. As redes neurais que atualmente podemos projetar são comparativamente tão primitivas quanto os circuitos locais e inter-regionais do cérebro. O que é realmente gratificante, contudo, é o progresso notável alcançado em várias frentes durante as últimas duas décadas. Com a analogia neurobiológica como fonte de inspiração e com a riqueza das ferramentas teóricas e tecnológicas que temos acumulado, estamos certos de que em mais uma década a compreensão das redes neurais artificiais será muito mais sofisticada do que ela o é atualmente. (Haykin, 2001).

2.3 – MODELOS DE UM NEURÔNIO

Um *neurônio* é uma unidade de processamento de informação que é fundamental para a operação de uma rede neural. Aqui nós identificamos três elementos básicos do modelo neuronal:

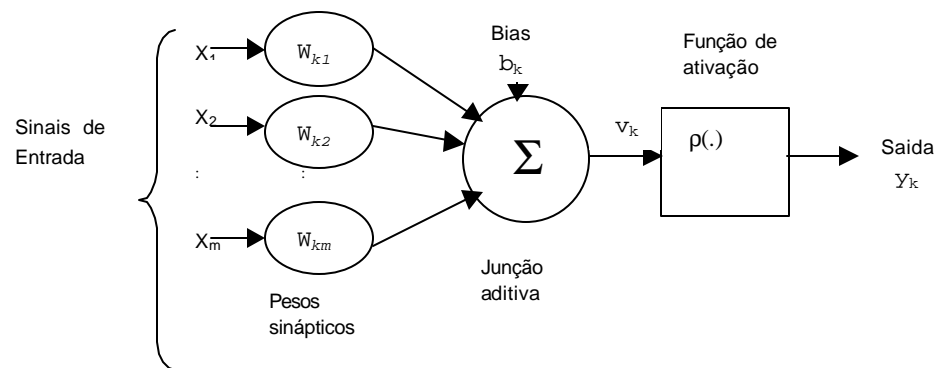


FIGURA 2.2 Modelo não-linear de um neurônio

1. Um conjunto de *sinapses* ou *elos de conexão*, cada uma caracterizada por um peso ou força própria. Especificamente, um sinal x_j na entrada da sinapse j conectada ao neurônio k é multiplicado pelo peso sináptico w_{kj} . O primeiro índice do peso sináptico se refere ao neurônio em questão e o segundo ao terminal de entrada da sinapse a qual o peso se refere, podendo estar em um intervalo que inclui valores negativos e positivos.

2. Um *somador* para somar os sinais de entrada, ponderados pelas respectivas sinapses do neurônio; as operações descritas aqui constituem um *combinador linear*.
3. Uma *função de ativação* para restringir a amplitude da saída de um neurônio. A função de ativação é também referida como *função restritiva* já que limita o intervalo permissível de amplitude do sinal de saída a um valor finito. O intervalo normalizado da amplitude da saída de um neurônio é escrito como intervalo unitário fechado $[0,1]$ ou alternativamente $[-1,1]$. (Haykin, 2001).

2.4 – ARQUITETURAS DE REDE

A maneira pela qual os neurônios de uma rede neural estão estruturados está intimamente ligada com o algoritmo de aprendizagem usado para treinar a rede. Pode-se, portanto, falar de algoritmos (regras) de aprendizagem utilizados no projeto de redes neurais como sendo *estruturados*. Em geral, pode-se identificar três classes de arquitetura de rede fundamentalmente diferentes:

1. **Redes alimentadas adiante com camada única** – Em uma rede neural *em camadas*, os neurônios estão organizados na forma de camadas. Na forma mais simples de uma rede em camadas, tem-se uma *camada de entrada* de nós de fonte que se projetam sobre uma *camada de saída* de neurônios (nós computacionais), mas não vice-versa. Esta rede é estritamente do tipo *alimentada adiante* ou *acíclica*, (Fig. 2.3) e chamada de *rede de camada única*, sendo que a designação “camada única” se refere à camada de saída de nós computacionais (neurônios). Não é contada a camada de entrada de nós de fonte, visto que na mesma não é realizada qualquer tipo de computação.




FIGURA 2.3 Rede alimentada adiante ou acíclica com uma única camada de neurônios

2. **Redes alimentadas diretamente com múltiplas camadas** – Uma rede neural alimentada adiante se distingue pela presença de uma ou mais *camadas ocultas*. A função dos neurônios ocultos é intervir entre a entrada externa e a saída da rede de uma maneira útil. Adicionando-se uma ou mais camadas ocultas, tornamos a rede capaz de extrair estatísticas de ordem elevada. Em um sentido bastante livre, a rede adquire uma perspectiva *global* apesar de sua conectividade local, devido ao conjunto extra de conexões sinápticas e da dimensão extra de interações neurais. A habilidade dos neurônios ocultos extraírem estatísticas de ordem elevada é particularmente valiosa quando o tamanho da camada de entrada é grande. Os nós de fonte de camada da rede fornecem os respectivos elementos do padrão de ativação (vetor de entrada), que constituem os sinais de entrada aplicados aos neurônios (nós computacionais) na segunda camada (i.e., a primeira camada oculta). Os sinais e saída da segunda camada são utilizados como entradas para a terceira camada, e assim por diante para o resto da rede. Tipicamente, os neurônios em camada da rede têm como suas entradas apenas os sinais de saída da camada precedente. O conjunto de sinais dos neurônios da camada de saída (final) da rede constitui a resposta global da rede para o padrão e ativação fornecidos pelos nós de fonte da camada de entrada (primeira).

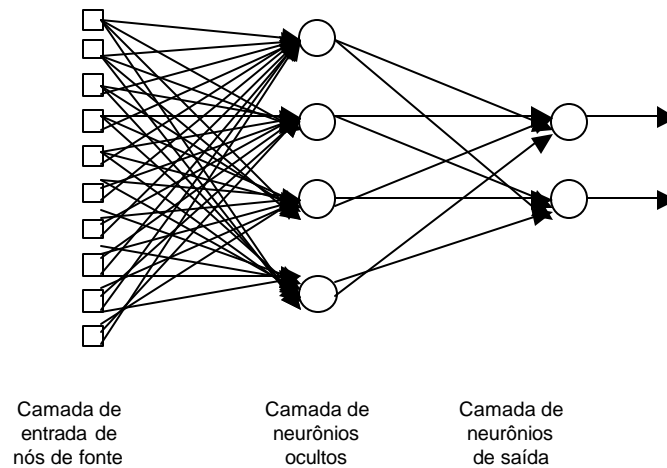


FIGURA 2.4 Rede alimentada adiante ou acíclica totalmente conectada com uma camada oculta e uma camada de saída

3. **Redes Recorrentes** – Uma *rede neural recorrente* se distingue de uma rede neural alimentada por ter pelo menos um laço de *realimentação*. Uma rede recorrente pode consistir, por exemplo, de uma única camada de neurônios com cada neurônio alimentando seu sinal de saída de volta para as entradas de todos os outros neurônios, Fig. 2.5. Neste caso, não há laços de auto-realimentação da rede; auto-realimentação se refere a uma situação onde a saída de um neurônio é realimentada para a sua própria entrada. A rede recorrente também *não* tem neurônios ocultos. A presença de laços de realimentação quer seja na estrutura recorrente da Fig. 2.5 ou naquela da Fig. 2.6, tem um impacto profundo na capacidade de aprendizagem da rede e no seu desempenho. Além disso, os laços de realimentação envolvem o uso de ramos particulares compostos de *elementos de atraso unitário*, o que resulta em um comportamento dinâmico não-linear, admitindo-se que a rede neural contenha unidades não-lineares. (Haykin, 2001).

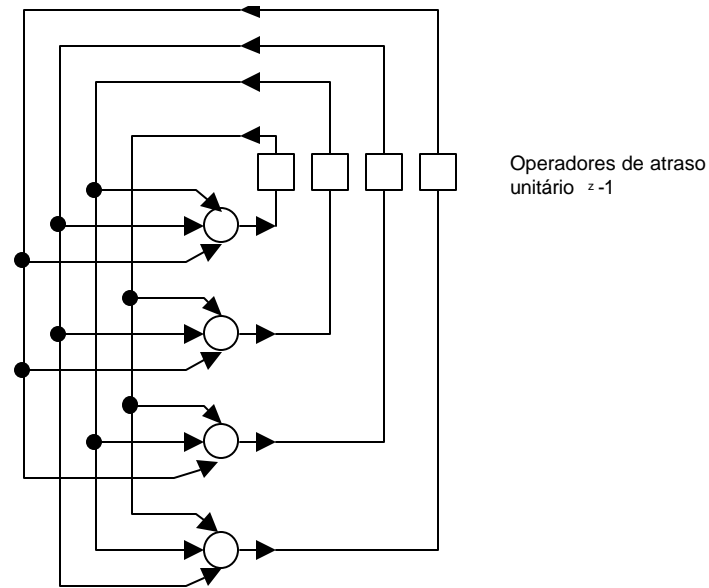


FIGURA 2.5 Rede recorrente sem laços de auto-realimentação e sem neurônios ocultos

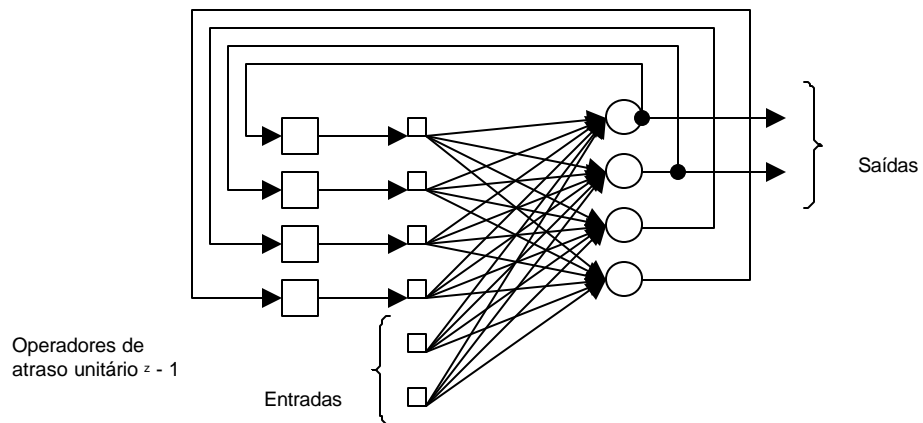


FIGURA 2.6 Rede recorrente com neurônios ocultos

2.5 – REPRESENTAÇÃO DO CONHECIMENTO

O termo “conhecimento” na definição de uma rede neural oferece a seguinte definição genérica (Fischler e Firschein, 1987) :

Conhecimento se refere à informação armazenada ou a modelos utilizados por uma pessoa ou máquina para interpretar, prever e responder apropriadamente ao mundo exterior.

São duas as principais características da *representação do conhecimento*:

1. Que informação é realmente tornada explícita;
2. Como a informação é codificada fisicamente para o uso subsequente.

Portanto, pela sua própria natureza, a representação do conhecimento é direcionada a um objetivo. Em aplicações do mundo real de máquinas “inteligentes”, pode-se dizer que uma boa solução depende de uma boa representação do conhecimento. Tipicamente, entretanto, as formas possíveis de representação desde as entradas até os parâmetros internos da rede são muito diversificadas, o que tende a tornar o desenvolvimento de uma solução satisfatória utilizando uma rede neural um desafio real de projeto.

Uma tarefa importante para uma rede neural é aprender um modelo do mundo (ambiente) no qual ela está inserida e manter o modelo suficientemente consistente com o mundo real de maneira a atingir os objetivos especificados da aplicação de interesse. O conhecimento do mundo consiste de dois tipos de informação:

1. O estado conhecido do mundo, representado pelos fatos sobre o que é e o que era conhecido; esta forma de conhecimento é chamada de *informação prévia*
2. As observações (medidas) do mundo, obtidas por meio de sensores projetados para sondar o ambiente no qual a rede neural deve operar. Normalmente, estas observações são inerentemente ruidosas, sendo sujeitas a erros devido a ruído do sensor e imperfeições do sistema. As informações que são assim obtidas fornecem o conjunto de informações de onde são retirados os *exemplos* utilizados para treinar a rede neural.

Os exemplos podem ser *rotulados* ou *não-rotulados*. Nos exemplos rotulados, cada exemplo que representa um *senal de entrada* é associado a uma *resposta desejada* correspondente. Por outro lado, os exemplos não-rotulados consistem de ocorrências diferentes dos próprios sinais de entrada. De qualquer maneira, um conjunto de exemplos, rotulados ou não, representa o conhecimento acerca do ambiente de interesse que uma rede neural pode aprender através de treinamento.

O projeto de uma rede neural é baseado diretamente nos dados do mundo real, *permitindo-se que o conjunto de dados fale por si mesmo*. Assim, a rede neural não somente fornece o modelo implícito do ambiente no qual ela está inserida, como também realiza a função de processamento de informações de interesse.

Os exemplos utilizados para treinar uma rede neural podem consistir tanto de exemplos *positivos* como de exemplos *negativos*.

O tema da representação do conhecimento no interior de uma rede artificial não é simples, existem quatro regras para a representação do conhecimento que são de senso comum (Anderson, 1988).

Regra 1. Entradas similares de classes similares normalmente devem produzir representações similares no interior da rede, portanto, devem ser classificadas como pertencentes à mesma categoria.

Regra 2. Devem ser atribuídas representações bem diferentes na rede a itens que devem ser categorizados como classes separadas, exatamente o oposto da Regra 1.

Regra 3. Se uma característica particular é importante, então deve haver um grande número de neurônios envolvidos na representação daquele item na rede.

Regra 4. Informação prévia e invariâncias devem ser incorporadas no projeto de uma rede neural, simplificando com isso o projeto da rede por não ter que aprendê-las.

A Regra 4 é particularmente importante porque a aderência adequada a ela resulta em uma rede neural com uma *estrutura especializada (restrita)*. Isto é altamente desejável por várias razões (Russo, 1991):

1. Sabe-se que as redes biológicas visuais e auditivas são muito especializadas.
2. Uma rede neural com estrutura especializada normalmente tem um número menor de parâmetros livres disponíveis para ajuste do que uma rede totalmente conectada. Conseqüentemente, a rede especializada requer um menor conjunto de dados para treinamento, aprende mais rápido e freqüentemente generaliza melhor.
3. A taxa de transmissão de informação através de uma rede especializada (i.e., a produtividade da rede) é acelerada.
4. O custo de construção de uma rede especializada é reduzido por causa do seu tamanho menor, quando comparado com a rede totalmente conectada equivalente.

2.6 – INTELIGÊNCIA ARTIFICIAL E REDES NEURAIAS

O Objetivo da *Inteligência artificial* (IA) é o desenvolvimento de paradigmas ou algoritmos que requeiram máquinas para realizar tarefas cognitivas, para as quais os humanos são atualmente melhores. Esta afirmação sobre a IA é tomada emprestada de Sage, 1990. Esta não é a única definição aceita para IA.

Um sistema de IA deve ser capaz de realizar três funções: (1) armazenar conhecimento, (2) aplicar o conhecimento armazenado para resolver problemas e (3) adquirir novo conhecimento através da experiência. Um sistema de IA tem três componentes fundamentais: representação, raciocínio e aprendizagem (Sage, 1990), como representado na Fig. 2.7

1. *Representação*. Provavelmente, a característica mais distinta de IA é o uso difundido de uma linguagem de estruturas *simbólicas* para representar tanto conhecimento genérico sobre um domínio do problema de interesse como o conhecimento específico sobre a solução do problema. Os símbolos são normalmente formulados em termos familiares, o que torna as representações simbólicas de IA relativamente fáceis de serem entendidas por um usuário humano.



FIGURA 2.7 Ilustração dos três componentes principais de um sistema de IA

“Conhecimento”, termo utilizado pelos pesquisadores de IA, é apenas mais uma referência a *dados*. Ele pode ser do tipo declarativo ou procedimental. Em uma representação *declarativa*, o conhecimento é representado como uma coleção estática de fatos, com um pequeno conjunto de procedimentos gerais utilizados para manipular fatos. Em uma representação *procedimental*, o conhecimento está incorporado a um código executável que representa o significado do conhecimento. Ambas as formas de conhecimento, declarativo e procedimental, são necessárias na maioria dos domínios de problemas de interesse.

2. *Raciocínio*, é a habilidade de resolver problemas. Para um sistema ser qualificado como um sistema de raciocínio, ele deve satisfazer certas condições (Fischler e Firschein, 1987):

- O sistema deve ser capaz de expressar e resolver uma vasta gama de problemas e tipos de problemas
- O sistema deve ser capaz de tornar conhecidas para ele tanto a informação *expícita* como a informação *implícita*.
- O sistema deve ter um mecanismo de controle que determine quais operações devem ser aplicadas para um problema particular, quando uma solução para este problema foi obtida, ou quando deve ser encerrado o tratamento deste problema.

A resolução de problemas pode ser vista como um problema de *busca*. Uma maneira comum de lidar com a “busca” é utilizar *regras, dados e controle* (Nilsson, 1980). As regras operam sobre os dados e o controle opera sobre as regras.

Em muitas situações encontradas na prática (p.ex., no diagnóstico médico), o conhecimento disponível é incompleto ou inexato. Em tais situações, são utilizados procedimentos de *raciocínio probabilístico*, permitindo deste modo que sistema de IA lidem com incertezas (Russell e Norvig, 1995; Pearl, 1988).

2. *Aprendizagem*. No modelo simples de aprendizagem de máquina representado na Fig. 2.8, o ambiente fornece alguma informação para um *elemento de aprendizagem*.




FIGURA 2.8 Modelo simples de aprendizagem de máquina

O elemento de aprendizagem utiliza, então, esta informação para aperfeiçoar a *base de conhecimento*, e finalmente o *elemento de desempenho* utiliza a base de conhecimento para executar a sua tarefa. Normalmente, a informação que o ambiente fornece para a máquina é imperfeita, resultando que o elemento de desempenho não sabe previamente como preencher os detalhes ausentes ou ignorar os detalhes que não são importantes. Portanto, a máquina opera inicialmente por suposição e depois recebe *realimentação* do elemento de desempenho. O mecanismo de realimentação permite que a máquina avalie suas hipóteses e as revise, se necessário.

A aprendizagem de máquina envolve dois tipos bastante diferentes de processamento de informação: o *indutivo* e o *dedutivo*. No processamento de informação *indutivo*, padrões gerais e regras são determinados a partir dos dados brutos e da experiência. No processamento de informação *dedutiva* são utilizadas regras gerais para determinar fatos específicos. A aprendizagem baseada em similaridade utiliza indução, enquanto que a prova de um teorema é uma dedução baseada em axiomas conhecidos e em outros teoremas existentes. A aprendizagem baseada em explanação utiliza tanto indução como dedução.

A importância das bases de conhecimento e as dificuldades experimentadas com a aprendizagem levaram ao desenvolvimento de vários métodos para aperfeiçoar as bases de conhecimento. Especificamente, se existirem especialistas em uma dada área, é normalmente mais fácil obter a experiência compilada dos especialistas do que tentar duplicar os experimentos que os levaram a adquirir esta experiência. Esta é a idéia por trás dos *sistemas especialistas*.

Em resumo, pode-se descrever a IA simbólica como a manipulação formal de uma linguagem de algoritmos e representações de dados em uma forma de cima para baixo (*top down*). Por outro lado, pode-se descrever as redes neurais como

processadores distribuídos paralelamente com uma habilidade natural para aprender e que normalmente operam de uma forma de baixo para cima. Portanto, torna-se evidente que, para a implementação de tarefas cognitivas, melhor que procurar soluções baseadas em IA simbólica ou redes neurais isoladamente, uma abordagem potencialmente mais vantajosa seria construir *modelos conexionistas estruturados* ou *sistemas híbridos* que integrem ambas as abordagens (Haykin, 2001).

2.7 – PROCESSOS DE APRENDIZAGEM

A propriedade que é de importância primordial para uma rede neural é a sua habilidade em *aprender* a partir do seu ambiente e de *melhorar* o seu desempenho através da aprendizagem. A melhoria do desempenho ocorre com o tempo de acordo com alguma medida preestabelecida. Uma rede neural aprende acerca do seu ambiente através de um processo interativo de ajustes aplicados a seus pesos sinápticos e níveis de *bias*. Idealmente, a rede se torna mais instruída sobre o seu ambiente após cada alteração do processo de aprendizagem.

Define-se aprendizagem no contexto de rede neural como:

Aprendizagem é um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros ocorre.

Esta definição do processo de aprendizagem implica na seguinte seqüência de eventos:

1. A rede neural é *estimulada* pelo ambiente.
2. A rede neural *sofre modificações* nos seus parâmetros livres como resultado desse estímulo.
3. A rede neural *responde de uma maneira nova* ao ambiente, devido às modificações ocorridas na sua estrutura interna.

Um conjunto preestabelecido de regras bem definidas para a solução de um problema de aprendizagem é denominado um *algoritmo de aprendizagem*. Basicamente, os algoritmos de aprendizagem diferem entre si pela forma como é formulado o ajuste

de um peso sináptico de um neurônio. Um outro fator a ser considerado é a maneira pela qual uma rede neural se relaciona como seu ambiente (Haykin, 2001).

2.8 – APRENDIZAGEM POR CORREÇÃO DE ERRO

Para ilustrar a primeira regra de aprendizagem, considere o caso simples de um neurônio k que constitui o único nó computacional da camada de saída de uma rede neural alimentada adiante, com representado na Fig. 2.9. O neurônio k é acionado por um *vetor de sinal* $\mathbf{x}(n)$ produzido por uma ou mais camadas de neurônios ocultos, que são, por sua vez, acionadas por um vetor de entrada (estímulo) aplicado aos nós de fonte (i.e., a camada de entrada) da rede neural. O argumento n representa o instante de tempo discreto, ou mais precisamente, o passo de tempo de um processo iterativo envolvido no ajuste dos pesos sinápticos do neurônio k . O *signal de saída* do neurônio k é representado por $y_k(n)$. Este sinal de saída, representando a única saída da rede neural, é comparado com uma *resposta desejada* ou *saída-alvo*, representado por $d_k(n)$. Conseqüentemente, é produzido um *signal de erro*, representado por $e_k(n)$.

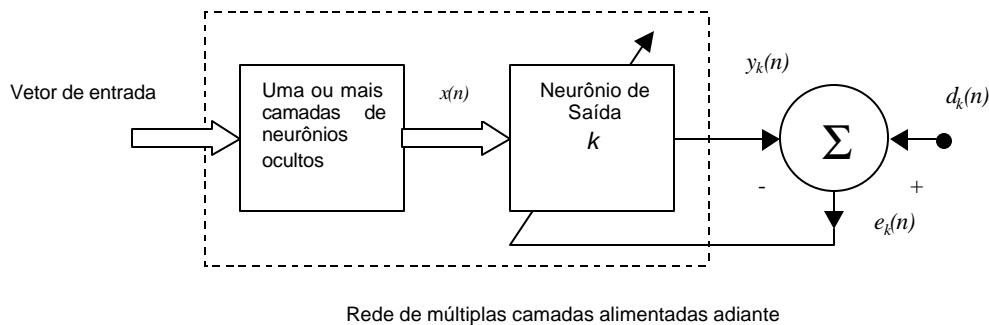


FIGURA 2.9 – Ilustração da aprendizagem por correção de erro

$$e_k(n) = d_k(n) - y_k(n)$$

O sinal de erro $e_k(n)$ aciona um *mecanismo de controle*, cujo propósito é aplicar uma seqüência de ajustes corretivos aos pesos sinápticos do neurônio k . Os ajustes corretivos são projetados para aproximar passo a passo o sinal de saída $y_k(n)$ da resposta desejada

$d_k(n)$. Este objetivo é alcançado minimizando-se uma *função de custo* ou *índice de desempenho*, $E(n)$, definido em termos do sinal de erro $e_k(n)$ como:

$$E(n) = \frac{1}{2} e_k^2(n)$$

Com isso, $E(n)$ é o valor instantâneo da energia do erro. O ajuste passo a passo dos pesos sinápticos do neurônio k continuam até o sistema atingir um *estado estável* (i.e., os pesos sinápticos estão essencialmente estabilizados). Neste ponto, o processo é encerrado. (Haykin, 2001).

2.9 – APRENDIZAGEM BASEADA EM MEMÓRIA

Na *aprendizagem baseada em memória*, todas as (ou a maioria das) experiências passadas são armazenadas explicitamente em uma grande memória de exemplos de entrada-saída classificados corretamente, onde \mathbf{x}_i representa um vetor de entrada e \mathbf{d}_i representa a resposta desejada correspondente. Sem perda de generalidade, restringimos a resposta desejada a ser um escalar. Em um problema de classificação de padrões binário, por exemplo, há duas classes/hipóteses a serem consideradas, representadas por C_1 e C_2 . Neste exemplo, a resposta desejada d_i assume o valor 0 (ou -1) para a classe C_1 e o valor 1 para a classe C_2 . Quando desejamos classificar um vetor de teste $\mathbf{X}_{\text{teste}}$ (não visto antes), o algoritmo responde buscando e analisando os dados de treinamento em uma “vizinhança local” de $\mathbf{X}_{\text{teste}}$.

Todos os algoritmos de aprendizagem baseada em memória envolvem dois ingredientes essenciais:

- O critério utilizado para definir a vizinhança local do vetor de teste $\mathbf{X}_{\text{teste}}$.
- A regra de aprendizagem aplicada aos exemplos de treinamento na vizinhança local de $\mathbf{X}_{\text{teste}}$.

Os algoritmos diferem entre si na forma como estes dois ingredientes são definidos. (Haykin, 2001).

2.10 – APRENDIZAGEM HEBBIANA

*O postulado de aprendizado de Hebb é a mais antiga e a mais famosa de todas as regras de aprendizagem; ele é assim denominado em homenagem ao neuropsicólogo Donald Hebb (1949). Citando o livro de Hebb (1949, p.62), *The Organization of Behavior* (i.e., A Organização do Comportamento).*

Quando um axônio da célula A está perto o suficiente para excitar uma célula B e participa do seu disparo repetido ou persistentemente, então algum processo de crescimento ou modificação metabólica acontece em uma das células ou em ambas, de tal forma que a eficiência de A como uma das células que dispara B é aumentada.

Hebb propôs esta modificação como uma base da aprendizagem associativa (a nível celular), que resultaria em uma modificação permanente do padrão de atividade de um “agrupamento de células nervosas” espacialmente distribuídos.

Definimos uma sinapse hebbiana como uma sinapse que usa um *mecanismo dependente do tempo, altamente local e fortemente interativo para aumentar a eficiência sináptica como uma função da correlação entre as atividades pré-sinápticas e pós-sinápticas*. A partir desta definição podemos deduzir os seguintes quatro mecanismos (propriedades) fundamentais que caracterizam uma sinapse hebbiana (Brown et al., 1990):

1. *Mecanismo dependente do tempo*. Este mecanismo se refere ao fato de que as modificações em uma sinapse hebbiana dependem do tempo exato de ocorrência dos sinais pré-sinápticos e pós-sinápticos.
2. *Mecanismo Local*. Pela sua natureza, uma sinapse local de transmissão onde sinais portadores de informação (representando a atividade incidente nas unidades pré-sinápticas e pós-sinápticas) estão em contigüidade *espaço-temporal*. Esta informação localmente disponível é utilizada uma sinapse hebbiana para produzir uma modificação sináptica local que é específica para a entrada.
3. *Mecanismo interativo*. A ocorrência de uma modificação de uma sinapse hebbiana depende dos sinais em ambos os lados da sinapse. Isto é, uma forma de aprendizagem hebbiana depende de uma “interação verdadeira” entre os sinais pré-

sináptico e pós-sináptico, no sentido de que não podemos fazer uma previsão a partir de apenas duas atividades.

4. *Mecanismo conjuncional* ou *correlativo*. Uma interpretação do postulado de aprendizado de Hebb é que a condição para uma modificação da eficiência sináptica é a conjunção dos sinais pré-sináptico e pós-sináptico. Assim, de acordo com esta interpretação, a ocorrência simultânea dos sinais pré-sináptico e pós-sináptico (dentro de um curto intervalo de tempo) é suficiente para produzir a modificação sináptica. Uma sinapse hebbiana é também denominada uma *sinapse correlativa*. A correlação é de fato a base do aprendizado (Eggermont, 1990).

2.11 – APRENDIZAGEM COMPETITIVA

Na *aprendizagem competitiva*, como o nome implica, os neurônios de saída de uma rede neural competem entre si para se tornar ativos (disparar). Enquanto que em uma rede neural baseada na aprendizagem hebbiana, vários neurônios de saída podem estar ativos simultaneamente, na aprendizagem competitiva somente um único neurônio de saída está ativo em um determinado instante. É nessa característica que torna a aprendizagem competitiva muito adequada para descobrir características estatisticamente salientes que podem ser utilizadas para classificar um conjunto de padrões de entrada.

Existem três elementos básicos em uma regra de aprendizagem competitiva (Rumelhart e Zisper, 1985):

- Um conjunto de neurônios que são todos iguais entre si, exceto por alguns pesos sinápticos distribuídos aleatoriamente, e que por isso *respondem diferentemente* a um dados conjunto de padrões de entrada.
- Um *limite* imposto sobre a “força” de cada neurônio.
- Um mecanismo que permite que o neurônio *compita* pelo direito de responder a um dado subconjunto de entradas, de forma que somente *um* neurônio de saída, ou somente um neurônio por grupo, esteja ativo (i.e., “ligado”) em um determinado instante. O neurônio que vence a competição é denominado um *neurônio vencedor leva tudo*.

Na forma mais simples de aprendizagem competitiva, a rede neural tem uma única camada de neurônios de saída, estando cada neurônio totalmente conectado aos nós de entrada. A rede pode incluir conexões de realimentação entre os neurônios, as conexões de realimentação realizam *inibição lateral*, com cada neurônio tendendo a inibir o neurônio ao qual está lateralmente conectado. (Haykin, 2001).

2.12 – APRENDIZAGEM DE BOLTZMANN

A regra de aprendizagem de Boltzmann, assim chamada em homenagem a Ludwig Boltzmann, é um algoritmo de aprendizagem estocástico derivado de idéias enraizadas na mecânica estatística. Uma rede neural projetada com base na regra de aprendizagem de Boltzmann é denominada uma *máquina de Boltzmann* (Ackley et al., 1985; Hinton e Sejnowski, 1986).

Em uma máquina de Boltzmann, os neurônios constituem uma estrutura recorrente e operam de maneira binária, uma vez que, por exemplo, eles estão ou em estado “ligado” representado por +1, ou em estado “desligado” representado por -1. A máquina é caracterizada por uma *função de energia*, E , cujo valor é determinado pelos estados particulares ocupados pelos neurônios individuais da máquina.

Os neurônios de uma máquina de Boltzmann se dividem em dois grupos funcionais: os *visíveis* e os *ocultos*. Os neurônios visíveis fornecem uma interface entre a rede e o ambiente em que ela opera, enquanto que os neurônios ocultos sempre operam livremente. Há dois modos de operação a serem considerados:

- *Condição presa*, na qual os neurônios visíveis estão todos presos a estados específicos determinados pelo ambiente.
- *Condição de operação livre*, na qual todos os neurônios (visíveis e ocultos) podem operar livremente.

2.13 – APRENDIZAGEM SUPERVISIONADA

A *aprendizagem supervisionada*, que é também denominada *aprendizagem com um professor*, Fig. 2.8. Em termos conceituais, podemos considerar o professor

como tendo conhecimento sobre o ambiente, com este conhecimento sendo representado por um conjunto de *exemplos de entrada-saída*.

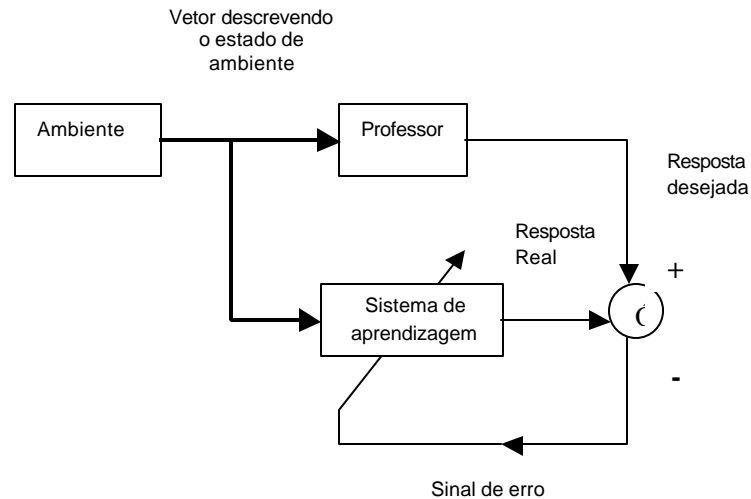


FIGURA 2.10 Diagrama em blocos da aprendizagem supervisionada

O ambiente é *desconhecido* pela rede neural de interesse. Supondo que o professor e a rede neural sejam expostos a um vetor de treinamento, ou seja, exemplos retirados do ambiente. Em virtude de seu condicionamento prévio, o professor é capaz de fornecer à rede neural uma resposta desejada para aquele vetor de treinamento. Na verdade, a resposta desejada representa a ação ótima a ser realizada pela rede neural. Os parâmetros da rede são ajustados sob a influência combinada do vetor de treinamento e do sinal de erro. O *sinal de erro* é definido como a diferença entre a resposta desejada e a resposta real. Este ajuste é realizado passo a passo, interativamente, com o objetivo de fazer a rede neural *emular* o professor; supõe-se que a emulação seja ótima em um sentido estatístico. Desta forma, o conhecimento do ambiente disponível ao professor é transferido para a rede neural através de treinamento, da forma mais completa possível. Quando esta condição é alcançada, podemos então dispensar o professor e deixar a rede neural lidar com o ambiente inteiramente por si mesma. (Haykin, 2001).

2.14 – APRENDIZAGEM NÃO SUPERVISIONADA

Na aprendizagem supervisionada, o processo de aprendizagem acontece sob a tutela de um professor. Entretanto, no paradigma conhecido como *aprendizagem sem um professor*, como o nome implica, *não* há um professor para supervisionar o processo de aprendizagem. Isto significa que não há exemplos rotulados da função a ser aprendida pela rede. Neste segundo paradigma, são identificadas suas subdivisões:

1. Aprendizagem por reforço/Programação neurodinâmica

Na *aprendizagem por reforço*, o aprendizado de um mapeamento de entrada-saída é realizado através da interação contínua com o ambiente, visando minimizar um índice escalar de desempenho. A figura 2.10 apresenta o diagrama em blocos de uma forma de sistema de aprendizagem por reforço construído em torno de um *crítico* que converte um *sinal de reforço primário* recebido do ambiente em um sinal de reforço de melhor qualidade, denominado *sinal de reforço heurístico*, sendo ambos entradas escalares (Barto et. al., 1983). O sistema é projetado para aprender por reforço atrasado, o que significa que o sistema observa uma seqüência temporal de estímulos (i.e., vetores de estímulos) também recebidos do ambiente, que eventualmente resultam na geração do sinal de reforço heurístico.

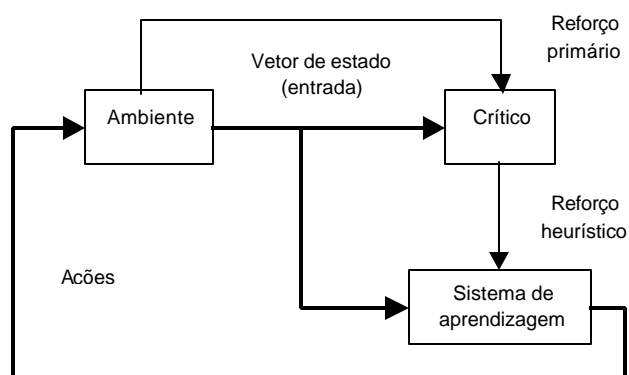


FIGURA 2.11 Diagrama em blocos da aprendizagem por esforço

A função da *máquina de aprendizagem*, que constitui o segundo componente do sistema, é *descobrir* estas ações e realimentá-las para o ambiente.

A aprendizagem por reforço atrasado é muito atraente. Ela fornece a base para o sistema interagir com o seu ambiente, desenvolvendo com isso a habilidade de aprender a realizar uma tarefa predeterminada com base apenas nos resultados de sua experiência, que resultam da interação.

2. Aprendizagem não supervisionada

Na aprendizagem não-supervisionada ou auto-organizada, não há um professor externo ou um crítico para supervisionar o processo de aprendizado, Fig. 2.12. Em vez disso, são dadas condições para realizar uma medida independente da tarefa da qualidade da representação que a rede deve aprender, e os parâmetros livre da rede são otimizados em relação a esta medida. Uma vez que a rede tenha se ajustado às regularidades estatísticas dos dados de entrada, ela desenvolve a habilidade de formar representações internas para codificar as características da entrada e, desse modo, de criar automaticamente novas classes (Becker, 1991).




FIGURA 2.12 Diagrama em blocos da aprendizagem não-supervisionada

Para realizarmos a aprendizagem não supervisionada, podemos utilizar a regra de aprendizagem competitiva. (Haykin, 2001).

2.15 – TAREFAS DE APRENDIZAGEM

A escolha de um algoritmo de aprendizagem particular é influenciada pela tarefa de aprendizagem que uma rede neural deve executar. Neste contexto, identificamos seis tarefas de aprendizagem que se aplicam ao uso de redes neurais de uma forma ou de outra.

2.15.1 - ASSOCIAÇÃO DE PADRÕES

Uma memória associativa é uma memória distribuída inspirada no cérebro, que aprende por associação. Desde Aristóteles, sabe-se que a associação é uma característica proeminente da memória humana, e todos os modelos de cognição utilizam associação de uma forma ou de outra como a operação básica (Anderson, 1995).

A associação assume uma de duas formas: auto-associação ou heteroassociação. Na auto-associação, uma rede neural deve armazenar um conjunto de padrões (vetores), que são apresentados repetitivamente à rede. Subseqüentemente, apresenta-se à rede uma descrição parcial ou distorcida (ruidosa) de um padrão original armazenado e a tarefa é recuperar (recordar) aquele padrão particular. A heteroassociação difere da auto-associação pelo fato de um conjunto arbitrário de padrões de entrada ser associado a um outro conjunto arbitrário de padrões de saída. A auto-associação envolve o uso de aprendizagem não-supervisionada, enquanto que, na heteroassociação, a aprendizagem é supervisionada.

2.15.2 - RECONHECIMENTO DE PADRÕES

Os seres humanos são bons no reconhecimento de padrões. Recebemos dados do mundo à nossa volta através dos nossos sentidos e somos capazes de reconhecer a fonte de dados.

O reconhecimento de padrões é formalmente definido como o processo pelo qual um padrão/sinal recebido é atribuído a uma classe dentre um número predeterminado de classes (categorias). Uma rede neural realiza o reconhecimento de padrões passando inicialmente por uma seção de treinamento, durante a qual se apresenta repetidamente à rede um conjunto de padrões de entrada junto com a categoria à qual cada padrão particular pertence. Mais tarde apresenta-se à rede um novo padrão que não foi visto antes, mas que pertence à mesma população de padrões utilizada para treinar a rede. A rede é capaz de identificar a classe daquele padrão particular por causa da informação que ela extraiu dos dados de treinamento.

2.15.3 - APROXIMAÇÃO DE FUNÇÕES

Considere um mapeamento de entrada-saída não linear descrito pela relação funcional

$$\mathbf{d} = \mathbf{f}(\mathbf{x})$$

onde o vetor \mathbf{x} é a entrada e o vetor \mathbf{d} é a saída. Supõe-se que a função de valor vetorial $\mathbf{f}(\cdot)$ seja desconhecida, e seja fornecido um conjunto de exemplos rotulados:

$$T = \{(\mathbf{x}_i, \mathbf{d}_i)\}_{i=1}^n$$

O objetivo é projetar uma rede neural que aproxime a função desconhecida $\mathbf{f}(\cdot)$ de forma que a função $\mathbf{F}(\cdot)$ que descreve o mapeamento de entrada-saída realmente realizado pela rede esteja suficientemente próxima a $\mathbf{f}(\cdot)$, em sentido euclidiano, sobre todas as entradas, como mostrado por:

$$\|\mathbf{F}(\mathbf{x}) - \mathbf{f}(\mathbf{x})\| < \mathbf{e} \text{ para todo } \mathbf{x}$$

onde \mathbf{e} é um número positivo pequeno. Contando que no tamanho N do conjunto de treinamento seja suficientemente grande e que a rede esteja equipada com um número adequado de parâmetros livres, então pode-se fazer o erro aproximativo \mathbf{e} suficientemente pequeno para a tarefa.

O problema de aproximação descrito aqui é um candidato perfeito para a aprendizagem supervisionada, com \mathbf{x}_i desempenhando o papel de vetor de entrada e \mathbf{d}_i desempenhando o papel da resposta desejada. Podemos então inverter esta questão e ver aprendizagem supervisionada como um problema de aproximação.

2.15.4 – CONTROLE

O controle de uma *planta* é uma outra tarefa de aprendizagem que pode ser feita por uma rede neural; aqui, “planta” significa um processo ou uma parte crítica de um sistema que deve ser mantido em uma condição controlada. A relevância da aprendizagem para o controle não deveria ser surpreendente porque, afinal, o cérebro

humano é um computador (i.e., um processador de informação), que, visto como um sistema, produz saídas que são *ações*.

Considere o *sistema de controle realimentado* da Fig. 2.13. O sistema envolve o uso de realimentação unitária em torno de uma planta a ser controlada; isto é, a saída da planta é realimentada diretamente para a entrada. Com isso, a saída da planta y é subtraída de um *signal de referência* d fornecido por uma fonte externa. O sinal de erro e assim produzido é aplicado a um *controlador* neural com o propósito de ajustar os seus parâmetros livres. O objetivo principal do controlador é fornecer entradas apropriadas para a planta, fazendo com que a sua saída y siga o sinal de referência d . Em outras palavras, o controlador deve inverter o comportamento de entrada-saída da planta.




FIGURA 2.13 Diagrama em blocos de um sistema de controle realimentado

Podemos adotar a abordagem *Aprendizagem indireta* ou a *Aprendizagem direta* para tratar esse problema. (Haykin, 2001).

2.15.5 – FILTRAGEM

O termo *filtro* se refere freqüentemente a um dispositivo ou algoritmo utilizado para extrair informação sobre uma determinada grandeza de interesse a partir de um conjunto de dados “ruidosos”. O ruído pode surgir de uma variedade de fontes. Os dados podem ter sido medidos por meio de sensores “ruidosos”, por exemplo, ou podem representar um sinal portador de informação que foi corrompido pela transmissão através de um canal de comunicação. Como outro exemplo, pode-se ter uma componente de sinal útil, corrompida por um sinal de interferência captado do meio ambiente. Podemos utilizar um filtro para realizar três tarefas básicas de processamento de informação:

1. *Filtragem*. Esta tarefa se refere à extração de informação sobre uma quantidade de interesse no tempo discreto n , utilizando dados medidos até o tempo n , inclusive.
2. *Suavização*. Esta segunda tarefa difere da filtragem pelo fato de que não é necessário que a informação sobre a grandeza de interesse esteja disponível no tempo n e de que os dados medidos após o tempo n podem ser usados para obter esta informação. Isto significa que, na suavização, há um *atraso* na produção do resultado de interesse.
3. *Previsão*. Esta tarefa corresponde ao lado preditivo do processamento de informação. O objetivo aqui é derivar informação sobre como será a grandeza de interesse em um determinado tempo $n + n_0$ no futuro, para algum $n_0 > 0$, utilizando os dados medidos até o tempo n inclusive. A previsão pode ser resolvida utilizando-se aprendizagem por correção de erro em uma maneira não-supervisionada, já que os exemplos de treinamento são retirados diretamente do próprio processo.

2.15.6 - FORMAÇÃO DE FEIXE

A formação de feixe é uma forma de filtragem *espacial* e é utilizada para distinguir entre as propriedades espaciais de um sinal-alvo e o ruído de fundo. O dispositivo usado para realizar a formação de feixe é chamado de *formador de feixe*.

A formação de feixe é normalmente utilizada em sistemas de radar e sonar nos quais a tarefa principal é detectar e perseguir um alvo de interesse na presença combinada de ruído do receptor e sinal de interferência (p.ex., obstrutores). Esta tarefa é complicada por dois fatores.

- O sinal-alvo se origina em uma direção desconhecida.
- Não há informação *a priori* disponível sobre os sinais de interferência.

Uma forma de lidar com situações deste tipo é utilizando um *cancelador de lóbulo lateral generalizado* (CLLG), Fig. 2.14. O sistema consiste dos seguintes componentes (Griffiths e Jim, 1982; Van Veen, 1992; Haykin, 1996):

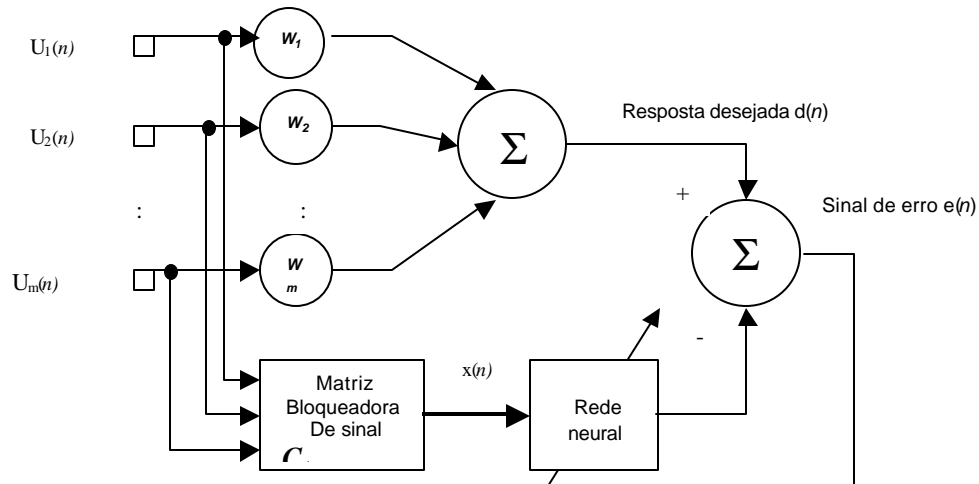


FIGURA 2.14 Diagrama em blocos do cancelador de lóbulo lateral generalizado

- Um *arranjo de elemento de antenas*, que forneça um meio de amostrar o sinal observado em pontos discretos do espaço.
- Um *combinador linear* definido por um conjunto de pesos fixos, cuja saída é uma resposta desejada. Este combinador linear age como um “Filtro espacial”, sendo caracterizado por um padrão de radiação (i.e., um gráfico polar da amplitude de saída da antena em função do ângulo de incidência de um sinal incidente).
- Uma *matriz bloqueadora de sinal* C_a , cuja função é cancelar a interferência que escapa através dos lóbulos laterais do padrão de radiação do filtro espacial que representa o combinador linear.
- Uma *rede neural* com parâmetros ajustáveis, que é projetada para acomodar variações estatísticas nos sinais de interferência.

2.16 – MEMÓRIA

A discussão de tarefas de aprendizagem, particularmente a tarefa de associação de padrões, nos leva naturalmente a refletir sobre a *memória*. Em um contexto neurobiológico, memória se refere às alterações neurais relativamente duradouras induzidas pela interação de um organismo com o seu ambiente (Teyler, 1986). Sem esta alteração não pode haver memória. Além disso, para que a memória seja útil, ela deve

ser acessível ao sistema nervoso para poder influenciar o comportamento futuro. Entretanto, um padrão de atividade deve ser inicialmente armazenado na memória através de um *processo de aprendizagem*. Memória e aprendizagem são conectadas de forma intrincada. Quando um padrão de atividade particular é aprendido, ele é armazenado no cérebro, de onde pode ser recuperado mais tarde, quando exigido. A memória se divide em memória de “curto prazo” e de “longo prazo”, dependendo do tempo de retenção (Arbib, 1989). *Memória de curto prazo* se refere a uma compilação de conhecimento que representa o estado “corrente” do ambiente. Quaisquer discrepâncias entre o conhecimento armazenado na memória de curto prazo e um “novo” estado são usadas para atualizar a memória de curto prazo. *Memória de longo prazo*, por outro lado, se refere ao conhecimento armazenado por um longo período ou permanente. Uma memória associativa oferece as seguintes características:

- A memória é distribuída.
- Tanto os padrões de estímulo (chave) como os padrões de resposta (armazenados) de uma memória associativa consistem de vetores de dados.
- A informação é armazenada na memória estabelecendo-se um padrão espacial de atividades neurais através de um grande número de neurônios.
- A informação contida em um estímulo não apenas determina o seu local de armazenamento mas também o endereço para sua recuperação.
- Embora os neurônios não representem células computacionais confiáveis e de baixo ruído, a memória exibe um alto grau de resistência a ruído e a falhas, de uma forma difusa.
- Pode haver interações entre padrões individuais armazenados na memória (De outra forma, a memória deveria ser excepcionalmente grande para acomodar o armazenamento de um grande número de padrões em perfeito isolamento entre si.) Existe, portanto, a possibilidade de a memória cometer *erros* durante o processo de recordação.

Em uma *memória distribuída*, as questões básicas de interesse são as atividades simultâneas ou quase simultâneas de muitos neurônios diferentes, que são o resultado de estímulos externos ou internos. As atividades neurais formam um padrão espacial dentro

da memória que contém informação sobre os estímulos. Diz-se, portanto, que a memória realiza um mapeamento distribuído que transforma um padrão de atividade no espaço de entrada em um outro padrão de atividade no espaço de saída. Considerando uma rede neural idealizada que consiste de duas camadas de neurônios, podemos ilustrar algumas propriedades importantes de um mapeamento de memória distribuída. Cada neurônio da camada de entrada está conectado a todos os neurônios da camada de saída. As conexões sinápticas reais entre os neurônios são complexas e redundantes. Uma única junção ideal é utilizada para representar o efeito integrado de todos os contatos sinápticos entre os dendritos de um neurônio da camada de entrada e os ramos do axônio de um neurônio da camada de saída. O nível de atividade de um neurônio da camada de entrada pode afetar o nível de atividade de todos os neurônios da camada de saída.




FIGURA 2.15 Modelo de memória associativa utilizando neurônios artificiais

A situação correspondente para uma rede neural artificial está representada na Fig.2.15. Aqui temos uma camada de entrada de nós de fonte e uma camada de saída de neurônios agindo como nós computacionais. Neste caso, os pesos sinápticos da rede estão incluídos como partes integrantes dos neurônios da camada de saída.

Na análise matemática, supõe-se que a rede neural é linear. A implicação desta suposição é que cada neurônio age como um combinador linear. (Haykin, 2001).

2.17 – RESUMO DO PROCESSO DE APRENDIZAGEM

Neste resumo, apresentamos algumas questões importantes relativas às muitas facetas do processo de aprendizagem no contexto de redes neurais. Com isso, estabelecemos os fundamentos para o restante deste trabalho. As cinco regras de aprendizagem, *aprendizagem por correção de erro*, *aprendizagem baseada em memória*, *aprendizagem hebbiana*, *aprendizagem competitiva* e *aprendizagem de Boltzmann* são básicas para o projeto de redes neurais. Alguns destes algoritmos requerem a utilização de um professor e outros não. O ponto importante é que estas regras nos permitem ir muito além do alcançável por filtros adaptativa lineares, tanto em termos de capacidade como em universalidade.

No estudo da aprendizagem supervisionada, uma condição fundamental é a existência de um “professor” capaz de fornecer correções exatas para as saídas da rede quando um erro ocorrer, como na aprendizagem por correção de erro; ou de “fixar” em relação ao ambiente as unidades de entrada e de saída livres da rede, como na aprendizagem de Boltzmann. Nenhum destes modelos é possível em organismos biológicos, que não possuem as conexões nervosas recíprocas exatas necessárias para a retropropagação das correções de erro (em rede de múltiplas camadas alimentadas adiante), nem os meios nervosos para imposição de comportamento pelo mundo exterior. Apesar disso, a aprendizagem supervisionada estabeleceu-se como um paradigma poderoso para o projeto de redes neurais artificiais.

Por outro lado, regras de aprendizagem auto-organizada (não-supervisionada), tais como a aprendizagem hebbiana e a aprendizagem competitiva, são motivadas por considerações neurobiológicas. Entretanto, para aperfeiçoar o nosso entendimento sobre a aprendizagem auto-organizada, precisamos também buscar idéias relevantes na *teoria da informação* de Shannon. Devemos mencionar aqui o *princípio da máxima informação mútua (Infomax)* de Linsker (1988), que fornece o formalismo matemático para o processamento de informação em uma rede neural auto-organizada, de uma forma até certo ponto análoga à transmissão de informação em um canal de comunicação. (Haykin, 2001).

2.18 – PERCEPTRONS DE CAMADA ÚNICA

O perceptron é a forma mais simples de uma rede neural usada para classificação de padrões ditos *linearmente separáveis* (i.e., padrões que se encontram em lados opostos de um hiperplano). Basicamente, ele consiste de um único neurônio com pesos sinápticos ajustáveis e *bias*. O algoritmo usado para ajustar os parâmetros livres desta rede neural apareceu em um procedimento de aprendizagem desenvolvido por Rosenblatt (1958, 1962) para o seu modelo cerebral do perceptron. De fato, Rosenblatt provou que se os padrões (vetores) usados para treinar o perceptron são retirados de duas classes linearmente separáveis, então o algoritmo do perceptron converge e posiciona a superfície de decisão na forma de um hiperplano entre as duas classes. A prova de convergência do algoritmo é conhecida como o *teorema de convergência do perceptron*. O perceptron construído em torno de um *único neurônio* é limitado a realizar classificação de padrões com apenas duas classes (hipóteses). Expandindo a camada de (computação) saída do perceptron para incluir mais de um neurônio, podemos correspondentemente realizar classificação com mais de duas classes. Entretanto, as classes devem ser linearmente separáveis para que o perceptron funcione adequadamente. O ponto importante é que, na medida em que consideramos a teoria básica do perceptron como um classificador de padrões, necessitamos considerar apenas o caso de um único neurônio. A extensão da teoria para caso de mais de um neurônio é trivial.

O neurônio único também forma a base de um *filtro adaptativo*, um bloco funcional que é básico para o tema do *processamento de sinais*, que está sempre em expansão. O desenvolvimento da filtragem adaptativa deve muito ao clássico artigo de Widrow e Hoff (1960), por criar o chamado *algoritmo do mínimo quadrado médio* (*LMS, least-mean-square*), também conhecido como a *regra delta*. O algoritmo LMS é simples de implementar e, no entanto, muito efetivo em relação à sua aplicação. Realmente, ele é o carro chefe da filtragem adaptativa *linear*, linear no sentido de que o neurônio opera no seu modo linear. Os filtros adaptativos têm sido aplicados com sucesso em campos tão diversos como antenas, sistemas de comunicação, sistemas de controle, radar, sonar, sismologia, e engenharia biomédica (Widrow e Stearns, 1985; Haykin, 1996).

2.19 – PERCEPTRONS DE MÚLTIPLAS CAMADAS

Tipicamente, a rede consiste de um conjunto de unidades sensoriais (nós de fonte) que constituem a *camada de entrada*, uma ou mais *camadas ocultas* de nós computacionais e uma *camada de saída* de nós computacionais. O sinal de entrada se propaga à frente através da rede, camada por camada. Estas redes neurais são normalmente chamadas de *perceptrons de múltiplas camadas* (MLP, *multilayer perceptron*), as quais representam uma generalização do perceptron de camada única.

Os perceptrons de múltiplas camadas têm sido aplicados com sucesso para resolver diversos problemas difíceis, através do seu treinamento de forma supervisionada com um algoritmo muito popular conhecido como *algoritmo de retropropagação de erro* (*error back-propagation*). Este algoritmo é baseado na *regra de aprendizagem por correção de erro*. Como tal pode ser visto como uma generalização de um algoritmo de filtragem adaptativa igualmente popular: o onipresente algoritmo do mínimo quadrado médio (LMS).

Basicamente, a aprendizagem por retropropagação de erro consiste de dois passos através das diferentes camadas da rede: um passo para frente, a *propagação*, e um passo para trás, a *retropropagação*. No *passo para frente*, um padrão de atividade (vetor de entrada) é aplicado aos nós sensoriais da rede e seu efeito se propaga através da rede, camada por camada. Finalmente, um conjunto de saídas é produzido como a resposta real da rede. Durante o passo de propagação, os pesos sinápticos da rede são todos fixos. Por outro lado, durante o *passo para trás*, os pesos sinápticos são todos *ajustados* de acordo com uma regra de correção de erro. Especificamente, a resposta real da rede é subtraída de uma resposta desejada (alvo) para produzir um *sinal de erro*. Este sinal de erro é então propagado para trás através da rede, contra a direção das conexões sinápticas – vindo daí o nome de “retropropagação de erro” (*error back-propagation*). Os pesos sinápticos são ajustados para fazer com que a resposta real da rede se mova para mais perto da resposta desejada, em um sentido estatístico. O algoritmo de retropropagação de erro é também definido na literatura como algoritmo de retropropagação (*back-propagation*). O processo de aprendizagem realizado com o algoritmo é chamado de *aprendizagem por retropropagação*.

Um perceptron de múltiplas camadas tem três características distintas:

1. O modelo de cada neurônio da rede inclui uma *função de ativação não-linear*. O ponto importante a se enfatizar aqui é que a não-linearidade é *suave* (i.e., diferenciável em qualquer ponto), ao contrário da limitação abrupta utilizada no perceptron de Rosenblatt. Uma forma normalmente utilizada de não linearidade que satisfaz esta exigência é uma *não-linearidade sigmóide* definida pela *função logística*:

$$y_j = \frac{1}{1 + \exp(-v_j)}$$

onde v_j é o campo local induzido (i.e., a soma ponderada de todas as entradas sinápticas acrescidas do bias) do neurônio j , e y_j é a saída do neurônio. A presença de não-linearidade é importante porque, do contrário, a relação de entrada-saída da rede poderia ser reduzida àquela de um perceptron de camada única.

2. A rede contém uma ou mais camadas de *neurônios ocultos*, que não são parte da entrada ou da saída da rede. Estes neurônios ocultos capacitam a rede a aprender tarefas complexas extraindo progressivamente as características mais significativas dos padrões (vetores) de entrada.
3. A rede exibe um alto grau de *conectividade*, determinado pelas sinapses da rede. Uma modificação na conectividade da rede requer uma mudança na população das conexões sinápticas ou de seus pesos.

É através da combinação destas características, juntamente com a habilidade de aprender da experiência através do treinamento, que o perceptron de múltiplas camadas deriva seu poder computacional. Estas mesmas características, entretanto, são também responsáveis pelas deficiências no estado atual do nosso conhecimento sobre o comportamento da rede. Primeiro, a presença de uma forma distribuída de não-linearidade da rede e a alta conectividade da rede tornam difícil a análise teórica de um perceptron de camadas múltiplas. Segundo, a utilização de neurônios ocultos torna o processo de aprendizagem mais difícil de ser visualizado. Em um sentido implícito, o processo de aprendizagem deve decidir quais as características do padrão de entrada devem ser representadas pelos neurônios ocultos. O processo de aprendizagem, conseqüentemente, torna-se mais difícil porque a busca deve ser conduzida em um

espaço muito maior de funções possíveis, e deve ser feita uma escolha entre representações alternativas do padrão de entrada (Hinton, 1989).

O algoritmo de retropropagação, basicamente, é uma técnica (derivativa) de gradiente, e não de uma técnica de otimização. A retropropagação possui duas propriedades distintas:

- É *simples* de calcular localmente
- Realiza a descida *estocástica* do gradiente no espaço de pesos (para a atualização de padrão em padrão dos pesos sinápticos).

Estas duas propriedades da aprendizagem por retropropagação no contexto de um perceptron de múltiplas camadas são responsáveis por suas vantagens e desvantagens.

O emprego do termo “retropropagação” (*back-propagation*) parece ter sido desenvolvido após 1985, quando seu uso foi popularizado pela publicação do livro *Parallel Distributed Processing*, (Rumelhardt e McClelland, 1986).

O desenvolvimento do algoritmo de retropropagação representa um marco nas redes neurais, pois fornece um método *computacional eficiente* para o treinamento de perceptrons de múltiplas camadas. Apesar de não podermos afirmar que o algoritmo de retropropagação forneça uma solução ótima para todos os problemas resolúveis, ele acabou com o pessimismo sobre a aprendizagem em máquinas de múltiplas camadas que havia sido causado pelo livro de Minsky e Papert (1969), (Haykin, 2001).

2.20 – O PROBLEMA DA FILTRAGEM ADAPTATIVA

O problema que abordamos é o de como projetar um *modelo* de múltiplas entradas-única saída do sistema dinâmico desconhecido, construindo-o em torno de um único neurônio linear. O modelo neural opera sob a influência de um algoritmo que *controla* os ajustes necessários dos pesos sinápticos do neurônio, considerando os seguintes pontos:

- O algoritmo inicia com uma *configuração arbitrária* para os pesos sinápticos do neurônio.

- Os ajustes dos pesos sinápticos, em resposta às variações estatísticas do comportamento do sistema, são feitas de forma *contínua* (i.e., o tempo é incorporado na constituição do algoritmo).
- Os cálculos dos ajustes dos pesos sinápticos são completados dentro de um intervalo de tempo que é igual a um período de amostragem.

O modelo neuronal descrito é conhecido como um *filtro adaptativo*. Apesar da descrição ser apresentada no contexto de uma tarefa claramente reconhecida como de *identificação de sistema*, a caracterização do filtro adaptativo é suficientemente genérica para ter ampla aplicação.




FIGURA 2.16– Grafo de fluxo de sinal do modelo adaptativo para o sistema

A figura 2.16 apresenta um grafo de fluxo de sinal do filtro adaptativo. A sua operação consiste de dois processos contínuos:

1. *Processo de filtragem*, que envolve a computação de dois sinais:
 - Uma saída, representada por $y(i)$, que é produzida em resposta aos m elementos do vetor de estímulo $\mathbf{x}(i)$, isto é, $x_1(i), \dots, x_m(i)$.
 - Um sinal de erro, representado por $e(i)$, que é obtido comparando-se a saída $y(i)$ com a saída correspondente $d(i)$ produzida pelo sistema desconhecido. Na verdade, $d(i)$ age como uma *resposta desejada* ou *sinal-alvo*.

2. *Processo adaptativo*, que envolve o ajuste automático dos pesos sinápticos do neurônio, de acordo com o sinal de erro $e(i)$.

Assim, a combinação destes dois processos atuando juntos constitui um *laço de realimentação* que age em torno do neurônio. (Haykin, 2001).

2.21 – O PERCEPTRON

Enquanto que o algoritmo LMS (i.e., *algoritmo do mínimo quadrado médio*) é construído em torno de um neurônio linear, o perceptron é construído em torno de um neurônio não-linear, isto é, o *modelo de McCulloch-Pitts* de um neurônio. Este modelo de neurônio consiste de um combinador linear seguido por um limitador abrupto (realizando a função sinal), como representado na Fig. 2.17. O nó aditivo do modelo neuronal calcula uma combinação linear das entradas aplicadas às suas sinapses e também incorpora um bias aplicado externamente. A soma resultante, isto é, o campo local induzido, é aplicado ao limitador abrupto. Correspondentemente, o neurônio produz uma saída igual a +1 se a entrada do limitador abrupto for positiva e -1 se ela for negativa.




FIGURA 2.17 – Grafo de fluxo de sinal do perceptron

No modelo de grafo de fluxo de sinal da Fig. 2.17, os pesos sinápticos do perceptron são representados dos por w_1, w_2, \dots, w_m . Correspondentemente, as entradas aplicadas ao perceptron são representadas por x_1, x_2, \dots, x_m . O bias aplicado externamente

é representado por b . Do modelo constatamos que a entrada do limitador abrupto ou o campo local induzido do neurônio é

$$V = \sum_{i=1}^m w_i x_i + b$$

O objetivo do perceptron é classificar corretamente o conjunto de estímulos aplicados externamente x_1, x_2, \dots, x_m em uma de duas classes C_1 ou C_2 . A regra de decisão para a classificação é atribuir o ponto representado pelas entradas x_1, x_2, \dots, x_m à classe C_1 se a saída do perceptron y for $+1$ e à classe C_2 se ela for -1 .

Para compreender melhor o comportamento de um classificador de padrões, normalmente traça-se um mapa das regiões de decisão no espaço e sinal m -dimensional abrangido pelas m variáveis de entrada x_1, x_2, \dots, x_m . Na forma mais simples do perceptron, existem duas regiões separadas por um *hiperplano* definido por:

$$\sum_{i=1}^m w_i x_i + b = 0$$

Isto está ilustrado na Fig. 2.18 para o caso de duas variáveis x_1 e x_2 , para o qual a fronteira de decisão toma a forma de uma linha reta. Um ponto (x_1, x_2) que se encontra acima da linha de fronteira é atribuído à classe C_1 e um ponto (x_1, x_2) que está abaixo da linha de fronteira é atribuído à classe C_2 . Note também que o efeito do bias b é meramente de deslocar a fronteira de decisão em relação à origem.

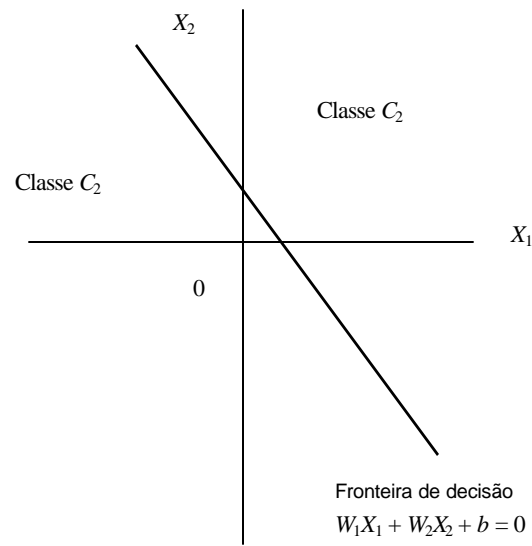


FIGURA 2.18 – Ilustração do hiperplano (neste exemplo, uma linha reta) como fronteira de decisão para um problema de classificação de padrões bidimensional de duas classes.

Os pesos sinápticos de W_1, W_2, \dots, W_m do perceptron podem ser adaptados de iteração para iteração. Para a adaptação podemos utilizar uma regra de correção de erro conhecida como o *algoritmo de convergência do perceptron*.

O perceptron e um filtro adaptativo utilizando o algoritmo LMS são naturalmente inter-relacionados, como evidenciado pela atualização de seus pesos. Na verdade, representam diferentes implementações de um *perceptron de camada única baseado em aprendizagem por correção de erro*. O termo “camada única” é usado aqui para significar que em ambos os casos a camada computacional consiste de um único neurônio. Entretanto, o perceptron e o algoritmo LMS diferem entre si em alguns aspectos fundamentais:

- O algoritmo LMS utiliza um neurônio linear, enquanto que o perceptron usa o modelo formal de um neurônio de McCulloch-Pitts.
- O processo de aprendizagem no perceptron é realizado para um número finito de iterações e então é encerrado. No algoritmo LMS, ao contrário, ocorre

aprendizagem contínua, significando que a aprendizagem acontece enquanto o processamento do sinal está sendo realizado, de uma forma que nunca acaba.

Um limitador abrupto constitui o elemento não-linear do neurônio de McCulloch-Pitts. Podemos, portanto afirmar formalmente que, desde que nos limitemos ao modelo de um neurônio que consista de um combinador linear seguido de um elemento não-linear, então, independentemente da forma da não-linearidade utilizada, um perceptron de camada única pode realizar classificação de padrões apenas sobre padrões linearmente separáveis. (Haykin, 2001).

2.22 – SOFTWARE MODELADOR DE REDES NEURAIS PYTHIA

Pythia é um programa (shareware até 13 neurônios) para o desenvolvimento e modelagem de redes neurais. O programa Pythia utiliza o algoritmo das redes de back-propagation. (retropropagação). O exemplo da Fig. 2.19., tem 2 entradas e 1 saída. Contém duas camadas (níveis) de neurônios, nível 1 com 2 neurônios e nível 2 com 1 neurônio. O sistema sugere automaticamente a quantidade de neurônios de entrada, intermediários e saídas, de acordo com os dados a serem utilizados, permitindo a livre alteração dos valores de neurônios e de neurônios por níveis ou camadas.

Os parâmetros de rede ("pesos") são ajustados inicialmente ao valor aleatório. Durante a "fase de treinamento", a saída real da rede é comparada à saída desejada e o erro propagado para trás para a entrada da rede. Os parâmetros podem ser alterados e a rede novamente submetida à fase de aprendizado ou treinamento.




Figura 2.19 - Representa uma típica rede backpropagation

O software Pythia permite que você importe dados dos formatos diferentes, de arquivo texto ou do programa de planilhas como Microsoft Excel, selecionando e copiando os dados para a área de transferência do sistema operacional (clipboard), o software tem uma função para colar da área de transferência, para a tabela interna, definindo as tabulações ou separadores para ajuste na tabela.

Uma característica especial do software Pythia é o otimizador evolucionário que gera automaticamente redes apropriadas para uma série de dados, fornecidos para a rede treinar. Usa algoritmos evolucionários para a seleção e a geração de redes neurais. O otimizador evolucionário inicialmente cria uma geração contendo 50 redes criadas randomicamente e continuamente até achar uma rede com aptidão (*fitness*) de 100, ou pode continuar por 1000 gerações, o que pode levar horas ou dias computando.

A rede é processada da esquerda para a direita e cada saída de neurônios é calculada pela fórmula abaixo:

$$O_n = F(\sum_k I_k * W_{kn})$$

- O** é o neurônio da saída, **n** é número de neurônios,
- I_k** são os neurônios de entrada, **k** é o número de entradas,
- W_{kn}** são os pesos dos neurônios.
- F** é a função Fermi $1/(1+\text{Exp}(-4*(x-0.5)))$

Uma Rede Neural espera que qualquer valor de entrada e saída valor esteja entre 0 e 1. Por isso os dados de treinamento devem ser normalizados antes do aprendizado da rede. A *normalização* é calculada pelo menor e maior valor encontrado em cada coluna dos dados:

$$N(i) = (i - \text{low}) / (\text{high} - \text{low})$$

- i** é o valor de entrada ou saída
- low** é o menor valor
- high** é o maior valor

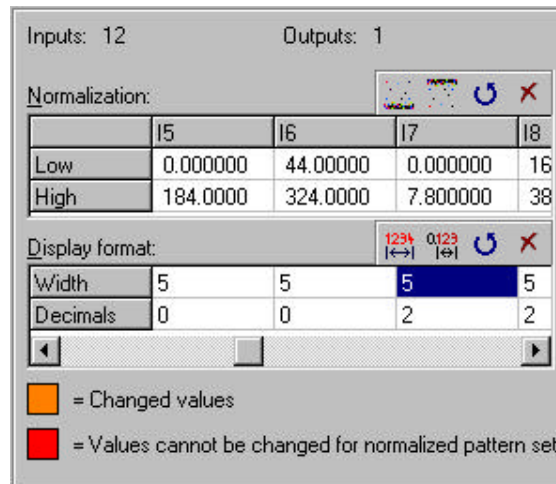


Figura 2.20 – Janela para normalização dos dados de entrada e saída

O sistema oferece a possibilidade do usuário entrar manualmente com um conjunto de dados para teste, tendo o mesmo número de variáveis e o posicionamento do conjunto de dados, separados por vírgulas.

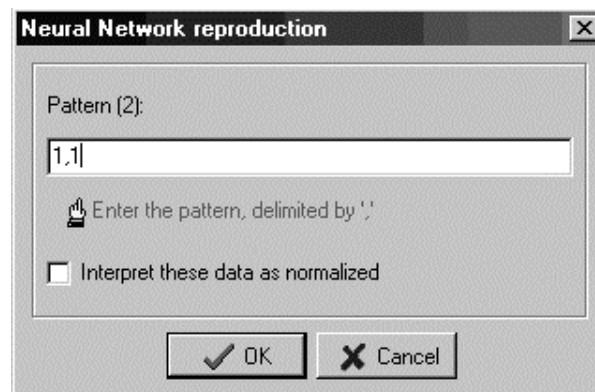


Figura 2.21 – Tela da entrada manual de dados para teste

O resultado desta operação será exibido na parte inferior da janela principal.

```
Normalized input is '1.000000, 1.000000'  
Normalized output is '0.077916'  
Output is '0.077916'  
Update net
```

Figura 2.22 – Resultado da entrada manual de dados

Permite que o seu trabalho seja salvo, e utilizado outras vezes, salvando a planilha de dados de entrada com ou sem os valores de saída, após o treinamento, e as redes criadas e otimizadas pelo sistema.

No capítulo 4 deste trabalho, é apresentado o processo de treinamento da rede com mais detalhes e figuras capturadas durante a fase de treinamento e análise do conjunto de dados da amostra.

O programa de redes neurais Pythia, é distribuído de forma *shareware*, podendo ser utilizado livremente em redes de até 13 neurônios, foi desenvolvido pela Runtime Software LLC - 1601 Fairview Drive - Suite H - Carson City - NV 89701 - e-mail info@runtime.org - Web <http://www.runtime.org>

CAPÍTULO 3

A doença aterosclerótica é a principal causa de mortalidade no Brasil, (DATASUS, Ministério da Saúde). Essa doença é multifatorial e a sua prevenção passa pela identificação e controle, não só das dislipidemias, mas do conjunto dos fatores de risco.

Em decorrência das inequívocas relações patogênicas evidenciadas entre a hiperlipidemia e a incidência da arteriosclerose, o estudo dos lipídios plasmáticos e a dosagem dessas substâncias no sangue ganhou extraordinário interesse clínico.

Apesar de estarmos numa época de tecnologia e de avanços em diagnósticos e terapêuticos em relação à doença arterial coronária, a realidade é que tal patologia ainda representa a principal causa de mortalidade e morbidade nos países ocidentais e será, sem dúvida, alvo de muita atenção no novo milênio, (Laures-Vale e Martinez, 2001). Um dos aspectos da DAC que traz particular preocupação é que muitas vezes o óbito ocorre como sua primeira manifestação, tornando, portanto, inútil qualquer forma terapêutica. Assim, o modo mais eficaz de combater esse problema é prevenir o seu aparecimento, desenvolvendo a profilaxia.

3.1. - Fatores de Risco (FR)

Um fator de risco, é qualquer traço ou característica que possa prever a probabilidade de um indivíduo vir a manifestar determinada doença; é um conceito moderno que combina a definição clássica de uma causa direta para determinada enfermidade com os conceitos mais recentes de probabilidade, predição e prognóstico. (Laures-Vale e Martinez, 2001).

Desde o primeiro relato do Estudo de Framingham (ERF), começou-se a destacar que determinados fatores pareciam estar ligados ao surgimento da doença

aterosclerótica. Na década de 60, o termo *fator de risco* começou a ser usado e propagou-se rapidamente.

O risco do indivíduo é medido e expresso como risco relativo (relativo a alguma referência ou padrão ideal) ou como risco absoluto (risco que uma pessoa possui de desenvolver determinado evento clínico em um período).

Risco relativo: é calculado como a incidência da doença entre os que estão expostos ou que tem o FR pela incidência da doença entre os que não estão expostos ou não apresentam o FR (anexo 10).

Risco atribuído (ou diferença de risco): é o risco absoluto atribuível à exposição a determinado FR. É definido como a diferença na incidência de determinada doença entre os indivíduos expostos e não-expostos.

Os *índices de risco* são os elementos analíticos principais, que, além de indicar a importância dos FR na enfermidade, constituem também um instrumento prático de prevenção, permitindo ao médico calcular o risco de seu paciente em relação ao que seria considerado ideal, para aquele indivíduo em questão (mesmo sexo e idade) (Laures-Vale e Martinez, 2001).

Segundo Assmann (1998), os critérios de avaliação de risco no diagnóstico lipídico, definidos nos *Simpósio Internacional de Lipídios*, Viena 1979, foram divididos em: *Isento de risco*, *Suspeita de risco*, *Requer tratamento*. Entretanto, o diagrama da “*Second joint Task Force of European and Societies on Coronary Prevention*”, tem uma avaliação mais abrangente, distribuída em cinco níveis de risco. (tab. 3.1)

Nível de Risco em 10 Anos		
Muito Alto	5	Acima de 40%
Alto	4	20 a 40%
Moderado	3	10 a 20%
Leve	2	05 a 10%
Baixo	1	Abaixo de 5%

Tabela 3.1 – Níveis de risco e percentuais de possibilidade de ocorrência dos fatores de risco.

3.2 – DOENÇA ARTERIAL CORONARIANA (DAC).

3.2.1 - ARTERIOSCLEROSE

A arteriosclerose, como o próprio nome indica, é uma doença das artérias, em especial as coronarianas, que transportam sangue e oxigênio ao músculo cardíaco, ou às carótidas, que irrigam o cérebro. Tal designação engloba um grupo de estados patológicos, cuja característica comum é o espessamento e perda de elasticidade das paredes arteriais. São em número de três as variantes morfológicas da doença: 1) aterosclerose, 2) esclerose calcificada da túnica média e 3) arteriosclerose. Esses tipos diferem entre si não só do ponto do vista morfológico, mas também quanto à etiologia e significação clínica.

Dado que a formação das placas de ateroma é extremamente lenta e se estende ao longo de vários anos, torna-se difícil acompanhar o processo.

A aterosclerose é uma doença extremamente freqüente, caracterizada por depósitos focais, sob a forma de placas fibroadiposas elevadas (ateromas), situados na espessura da íntima e da parte interna da túnica média das paredes arteriais. Tais placas podem com o tempo ulcerar-se, bem como causar estenose ou predispor à formação de aneurisma ou a rotura. Embora qualquer órgão ou tecido possa participar do processo aterosclerótico, tal alteração é mais freqüente no *coração, cérebro, rins, extremidades inferiores e intestino delgado*. (Miller, 1999)

3.2.2 - ATEROSCLEROSE

A preocupação com a dor torácica provavelmente já existia séculos antes de Hipócrates (460-370 a.C.), porém coube a ele o primeiro relato de *angina pectoris*, cuja descrição clínica como de origem coronariana, tal como a conhecemos hoje, só foi feita por Heberden em 1786, (Introcaso, 2001).

A aterosclerose é uma forma particular de arteriosclerose em que os depósitos de gordura começam a acumular-se, logo desde a infância, na parede das artérias. Com o tempo transformam-se em placas de ateroma, lesões fundamentais da aterosclerose.

Essas placas são compostas, principalmente, por colesterol e por derivados (ésteres) do colesterol.

A aterosclerose potencia a arteriosclerose "normal" provocada pelo envelhecimento. A sua gravidade varia conforme as pessoas e resulta de numerosos fatores, tanto internos como externos. Contrariamente a arteriosclerose vulgar, a distribuição da aterosclerose na rede arterial não é homogênea, atinge, principalmente, a aorta, as artérias femorais (das pernas), coronárias (do coração) e cerebrais. As placas de ateroma desenvolvem-se, sobretudo, nas zonas de grande turbulência do fluxo sanguíneo, especialmente onde existem bifurcações.

3.2.3 - ISQUEMIA

Isquemia é a carência de O₂ provocada por perfusão inadequada, resultante de desequilíbrio entre aporte e demanda de O₂ para o tecido. A causa mais comum de isquemia miocárdica é a doença aterosclerótica das artérias coronárias epicárdicas, com diminuição absoluta ou relativa da perfusão. Estas podem também limitar o fluxo sanguíneo coronariano: trombos arteriais, espasmos, (raramente) êmbolos coronarianos, anormalidades congênitas, hipertrofia ventricular grave provocada por HAS ou estenose aórtica. Também raramente ocorre por anemia extremamente grave ou presença de carboxiemoglobina. Estas duas causas geralmente coexistem, levando às manifestações clínicas da isquemia. Angina microvascular é a constrição anormal ou falha de dilatação anormal das arteríolas intramiocárdicas (vasos de resistência). A regulação da circulação coronariana que acompanha as necessidades de aporte de O₂ e o substrato denomina-se regulação metabólica, e a que acompanha as alterações fisiológicas da PA, de acordo com as necessidades miocárdicas chama-se auto-regulação.

Região	Mortalidade *
Norte	15,1
Nordeste	22,1
Sudeste	64,8
Sul	65,8
Centro-Oeste	30,4

* Óbitos/100.000 habitantes

Fonte: DATASUS, Ministério da Saúde (www.datasus.org.br)

Tabela 3.2 – Tabela de índice de óbitos no Brasil por região de doenças coronárias

3.3. – CLASSIFICAÇÃO DOS FATORES DE RISCO PARA DAC.

Existem dois tipos de fatores de risco (FR), segundo permitam, ou não, uma ação preventiva. Os fatores não modificáveis, que não permitem qualquer tipo de ação preventiva:

- A predisposição hereditária para desenvolver a aterosclerose é um fato inegável;
- A idade: algumas lesões mais ou menos graves vão-se desenvolvendo com o tempo;
- O sexo: os homens são muito mais afetados do que as mulheres e, sobretudo, quando são mais jovens.

No entanto, esta tendência tende a esbater-se, gradualmente, devido à evolução do estatus da mulher nas sociedades de tipo ocidental. De fato, também as mulheres se tornaram fumantes e estão, cada vez mais, expostas ao estresse. Mesmo assim, as mulheres em idade pré-menopáusia estão protegidas pelos hormônios sexuais femininos.

Entre, os fatores modificáveis, sobre os quais é possível agir preventivamente. Citamos:

- A hiperlipidemia e, sobretudo, a hipercolesterolemia secundária, devido a uma alimentação deficiente e pouco equilibrada, contendo um grande excesso de gorduras;
- O tabaco;
- O diabetes;
- A obesidade;
- A hipertensão arterial;
- O estresse;
- O sedentarismo ou, por outras palavras, a falta de exercício físico.

3.3.1 – *DISLIPIDEMIA*

Dislipidemia é um distúrbio do metabolismo que cursa com a alteração de uma ou mais frações dos lípidos séricos, quando então alcançam níveis associados com um

aumento de risco cardiovascular. Estes distúrbios metabólicos são capazes de causar doença aterosclerótica, sendo a doença arterial coronariana a principal delas.

O termo dislipidemia se refere tanto às anormalidades de natureza quantitativa como qualitativa dos lipídeos e particularmente no caso do HDL-colesterol se relaciona às baixas concentrações.

O acúmulo de evidências que apontam para o papel relevante da dislipidemia na patogenia da aterosclerose se faz há muito tempo.

Inúmeros estudos destacam a importância das dislipidemias na patogenia da aterosclerose, desde que Cohn em 1946 descreveu a técnica de eletroforese de lipoproteínas séricas, separando-as em alfa e beta lipoproteínas.

3.3.1.1 - CLASSIFICAÇÃO DAS DISLIPIDEMIAS

A classificação laboratorial das dislipidemias divide-se em:

- Hipercolesterolemia isolada (aumento do colesterol total, (CT) e ou LDL-colesterol, (LDL-C)).
- Hipertrigliceridemia isolada (aumento das triglicérides, TG).
- Hiperlipidemia mista (aumento do CT e dos TG).
- Diminuição isolada do HDL-colesterol (HDL-C) ou associada a aumento dos TG ou do LDL-C.

Os valores da tabela 3.3 de acordo com o Resumo das *III Diretrizes Brasileiras sobre Dislipidemias e Diretrizes de Prevenção da Aterosclerose do Congresso Brasileiro de Cardiologia*, realizado em Goiânia em 01/10/2001.

<i>Lípides</i>	<i>Valores</i>	<i>Categoria</i>
CT	< 200	Ótimo
	200 – 239	Limítrofe
	≥ 240	Alto
LDL-C	< 100	Ótimo
	100 – 129	Desejável
	130 – 159	Limítrofe
	160 – 189	Alto
	≥ 190	Muito Alto
HDL-C	< 40	Baixo
	> 60	Alto
	> 60	Alto
TG	< 150	Ótimo
	150 – 199	Limítrofe
	200 – 499	Alto
	≥ 500	Muito Alto

Tabela 3.3 – Valores de referência dos lipídios para indivíduos > 20 anos de idade – Valores em mg/dl
 Fonte: SBC. III Diretrizes Brasileiras sobre Dislipidemias e Diretrizes de Prevenção da Aterosclerose (2001).

3.3.1.2 – CLASSIFICAÇÃO ETIOLÓGICA

- Dislipidemias primárias

Origem genética.

- Dislipidemias secundárias

Causadas por outras doenças ou uso de medicamentos: hipotireoidismo, diabetes mellitus (DM), síndrome nefrótica, insuficiência renal crônica, obesidade, alcoolismo, icterícia obstrutiva, uso de doses altas de diuréticos, betabloqueadores, corticosteróides, anabolizantes.

3.3.1.3 – PERFIL LIPÍDICO

O *perfil lipídico* é definido pela determinação do **CT**, **HDL-C**, **TG** e quando possível, do **LDL-C** após jejum de 12 a 14 horas.

O valor do LDL-C é calculado através da fórmula de *Friedewald*:

$$LDL-C = CT - HDL-C - TG/5$$

(válida se TG < 400 mg/dl)

O perfil lipídico deve ser feito em indivíduos com estado metabólico estável; a dieta habitual e o peso devem ser mantidos por pelo menos duas semanas antes da realização do exame. Deve-se levar em consideração que, após qualquer doença ou cirurgias em geral o perfil lipídico do paciente pode estar temporariamente comprometido. Nenhuma atividade física vigorosa deve ser realizada nas 24 horas que antecedem o exame.

Os *lipídios* são substâncias orgânicas formadas por uma grande variedade de compostos. Os *lipídios* mais abundantes no plasma são representados pelo *colesterol*, *gorduras neutras (triglicerídios)* e *fosfolipídios*, existindo ainda pequenas quantidades de ácidos graxos livres, glicolipídios, bem como quantidades mínimas de hormônios e vitaminas de natureza lipídica.

As *gorduras neutras* ou *triglicerídios* são ésteres de ácido graxos com o glicerol (propanotriol). Os três ácidos graxos podem ser iguais entre si ou diferentes.

Os *fosfolipídios* são lipídios que exibem em sua estrutura um radical fosfato e incluem, como variedades principais, a *lecitina*, *cefalina* e *esfingomielina*.

O *colesterol* inclui-se num importante grupo de substâncias orgânicas complexas pertencentes à classe de lipídios, conhecidas como *esteróis*. É produzido principalmente pelo fígado a partir do acetato, sendo transformado em ácidos biliares, que são eliminados pela bile. O *colesterol* pode transformar ésteres com uma grande variedade de ácidos graxos, e normalmente dois terços do total existem sob essa forma de plasma.

3.3.1.4 - RESULTADOS NORMAIS

Quando se deseja pesquisar a hiperlipidemia como um dos fatores condicionantes da arteriosclerose, deve-se utilizar, a determinação plasmática de colesterol total e triglicerídios. As cifras normais dessas frações estão indicadas na tabela 3.4.

<i>Idade (anos)</i>	<i>Colesterol</i>	<i>Triglicéridios</i>
1 – 19	175 (120 – 230)	70 (10 – 140)
20 – 29	180 (120 – 240)	70 (10 – 140)
30 – 39	205 (140 – 270)	75 (10 – 150)
40 – 49	225 (150 – 310)	85 (10 – 160)
50 – 59	245 (160 – 330)	95 (10 – 190)

Tabela 3.4 Teor de Lipídios no Plasma (EUA)(mg/100ml)

Se ambos os valores estiverem dentro dos limites normais, não haverá necessidade de qualquer investigação adicional. Se um deles estiver elevado, ou ambos, torna-se imprescindível proceder a um estudo completo do metabolismo lipídico, incluindo um estudo eletroforético das lipoproteínas.

Lipídios totais	500 – 750
Colesterol total	150 – 230
Colesterol esterificado	90 – 130 (50-70% do total)
Colesterol livre	60 – 90
Triglicéridios	30 – 200
Fosfolipídios	
Até 65 anos	225 ± 32
Após 65anos	281 ± 85

Tabela 3.5 - Teores plasmáticos normais das diversas Frações Lipídicas (mg/100ml)

<i>Idade</i>	<i>HDL Colesterol Homens mg/dll</i>	<i>HDL Colesterol Mulheres mg/dll</i>
0 – 19	30 – 65	30 – 70
20 – 29	35 – 70	35 – 75
30 – 39	30 – 65	35 – 80
40 – 49	30 – 65	40 – 95
50 - 59	30 – 65	35 – 85

Tabela 3.6 - Teores Normais de Colesterol HDL - (Lipid Research Clinic – EUA)

3.3.1.5 - INTERPRETAÇÃO DAS ANOMALIAS DO LIPIDOGRAMA

Para fins clínicos, devem as hiperlipidemias ser consideradas como: a) primárias e b) secundárias a outras doenças. As *primárias* incluem principalmente as anormalidades provocadas por fatores alimentares ou ambientais, bem como as hiperlipoproteinemias essenciais ou familiares. Pode-se admitir que a maior parte das hiperlipidemias, seja de origem alimentar ou ambiental, aceitando-se, porém, a possibilidade de que uma sutil influência genética faça, com que a lipidemia de cada indivíduo responda de maneira diferente a idênticos estímulos alimentares ou ambientais.

São os seguintes os estados que se associam mais freqüentemente com *hiperlipidemias secundárias*:

1. Diabetes *melittus*
2. Ingestão de álcool (*mesmo em pequenas quantidades*)
3. Pancreatites
4. Hipotiroidismo
5. Síndrome nefrótica
6. Tesaurismose glicogênica
7. Hipercalcemia idiopática da infância
8. Globulinas plasmáticas anormais
9. Gravidez ou uso de anovulatórios
10. Hepatopatia obstrutiva
11. Os homens que sofreram infarto do miocárdio ou que aumentaram acima de 4,5 kg depois de terem atingido a idade madura, bem como as mulheres obesas.

Em indivíduos com menos de 25 anos, um teor de colesterol superior a 220 mg/100ml ou de triglicerídios acima de 150 mg/ml, indica hiperlipidemia suficiente para justificar que o clínico pesquise a existência de um dos fatores acima enumerados como causas de hiperlipidemias secundárias.

3.3.1.6 – COLESTEROL

O colesterol alto é uma das formas de hiperlipidemia, termo técnico que designa o aumento no sangue de um ou mais lípidos (colesterol, triglicérides ou ambos). O alto nível de gorduras no sangue, em especial o colesterol, pode acarretar problemas de longo prazo como a aterosclerose, que pode levar a doenças cardíacas e derrame cerebral (acidente vascular cerebral).

O colesterol também é fornecido pela alimentação; está presente exclusivamente, nos alimentos de origem animal: *carnes, frutos do mar, miúdos, gema de ovo, leite e derivados*, alimentos embutidos como: *lingüiça e salsicha*; frios: *salame e presunto*. Estes alimentos possuem gorduras saturadas e devem ser substituídos pelas gorduras poliinsaturadas, pois ajudam a diminuir os níveis de LDL.

Existem dois tipos de colesterol: HDL – pode ser considerado como "*benéfico*", conhecido como *colesterol bom*, tem a função de conduzir o excesso de colesterol para fora das artérias. Impedindo seu depósito, a LDL e VLDL, que são lipoproteínas "*maléficas*".

3.3.1.7 - CORRELAÇÃO ENTRE HIPERLIPIDEMIA E DAC

A hipercolesterolemia, que é o parâmetro mais estudado do metabolismo lipídico, reflete muito de perto o risco de *infarto*, não só no homem como na mulher, mas especialmente no primeiro. Num estudo que durou 14 anos, realizado por Kannel e colaboradores, a incidência relativa de infarto entre as idades de 30 e 49 anos com um nível de colesterol acima de 260mg/100ml foi quatro vezes maior do que a com colesterol abaixo de 220mg/100ml.

As lipoproteínas de baixa densidade (LDL) ou beta-lipoproteínas guardam com a *cardiopatía isquêmica* a mesma relação que o colesterol. As taxas de triglicéridios (ou de VLDL) também estão relacionadas com a incidência de cardiopatía isquêmica, e há estudos que sugerem ser a elevação dos triglicéridios (ou da VLDL) melhor índice de risco no homem jovem do que a do colesterol, bem como, a hiperlipidemia representa um risco mais significativo abaixo da idade de 50 anos e que ela atua independentemente da obesidade, hipertensão e diabetes. (Miller, 1999)

No tocante às lipoproteínas de alta densidade (HDL), a prevalência de cardiopatia isquêmica é inversamente proporcional ao seu teor plasmático (ver tabela 3.4). A HDL pode ser considerada, portanto, como “benéfica”, contrariamente ao que acontece com a LDL e VLDL, que são lipoproteínas “maléficas”. Isso obriga, em presença de hipercolesterolemia, a esclarecer se essa anormalidade se prende ao aumento da HDL ou da LDL (a VLDL vincula-se mais aos triglicerídios).

<i>HDL Colesterol mg/dl</i>	<i>Índice de risco de enfermidade coronária</i>	
	<i>Homens</i>	<i>Mulheres</i>
75 ou mais	Síndrome de Longevidade	
70	-	0,52
65	0,45	0,64
60	0,55	0,80
55	0,67	1,00 (normal)
50	0,82	1,25
45	1,00 (normal)	1,55
40	1,25	1,94
35	1,50	-
30	1,75	-
25 ou menos	2,00	-

Tabela 3.7 - Colesterol HDL e Risco de Cardiopatia Isquêmica

	<i>Colesterol total/HDL colesterol</i>	<i>Risco</i>
Homens	3,43	0,05 do Normal
	4,97	Normal
	9,55	2 x Normal
	14,00	3 x Normal
Mulheres	3,27	0,05 do Normal
	4,44	Normal
	7,05	2 x Normal
	11,04	3 x Normal

Tabela 3.8 – Relação Colesterol Total/Colesterol HDL e Risco de Cardiopatia Isquêmica

Assim, a dosagem do colesterol ligado às HDL é de grande valor clínico para avaliar o vulto do risco de cardiopatia isquêmica. Na tabela 3.7, observa-se que o risco para um homem com 25mg/dl de colesterol HDL será duas vezes menor, se ele tiver 45 mg/dl, e quatro vezes menor, se ele tiver 65 mg/dl. A tabela 3.8 mostra o risco de cardiopatia isquêmica em função da relação entre o colesterol total e o colesterol HDL, (Miller, 1999).

3.3.2. - TABAGISMO

O tabagismo é fator de risco independentemente para a aterosclerose e deve ser combatido de forma agressiva. Há fortes evidências demonstrando a relação causal entre o tabaco e desenvolvimento de DAC. Cerca de 6% das mortes no ano de 1990 foram decorrentes do consumo de cigarro, sendo 14,9% em regiões desenvolvidas e 3,7% nas regiões em desenvolvimento.

De acordo com dados do IBGE (1991), a prevalência de tabagismo em pessoas acima de cinco anos de idade foi de 24%, com maior concentração na faixa etária entre 30 e 49 anos. Outros estudos realizados entre 1971 e 1988 demonstraram que as taxas de prevalência de tabagismo variava de 35% a 40%. Recentemente, no estudo transversal da Sociedade de Cardiologia do Estado de São Paulo (1999) as taxas de prevalência de tabagismo foram de 17% (idade mediana de 46 ± 16 anos), após avaliação de aproximadamente 20 mil indivíduos em 19 cidades do estado.

3.3.3 – DIABETES (DM)

O DM é uma síndrome de etiologia múltipla, decorrente da falta de insulina e/ou da incapacidade de a insulina exercer adequadamente seus efeitos. Caracteriza-se por hiperglicemia crônica, com distúrbios do metabolismo de carboidratos, lipídios e proteínas. As conseqüências do DM a longo prazo incluem danos, disfunção e falência de vários órgãos, especialmente rins, olhos, nervos, coração e vasos sanguíneos. Com freqüência, os sintomas clássicos estão ausentes, porém a hiperglicemia de grau suficiente, pode causar alterações funcionais ou patológicas por um longo período antes que o diagnóstico seja estabelecido, (Costa e Forti, 2001).

Segundo critérios da Associação Americana de Diabetes, o diagnóstico de diabetes se dá quando a glicemia de jejum ultrapassar 125 mg/dl, o que deve ser confirmado por um segundo teste, realizado após jejum de oito a dez horas, conforme tabela abaixo:

<i>Estágio</i>	<i>Glicemia em jejum mg/dl</i>	<i>Glicemia casual mg/dl</i>	<i>OGTT (120')</i>
Diabetes	> 125	>200	> 200
Intolerância	Entre 110 e 125		Entre 140 e 200
Normal	< 110		< 140

Tabela 3.9 – Critérios diagnósticos da American Diabetes Association 1997

3.3.4 – OBESIDADE

A obesidade está geralmente associada a outros fatores de risco cardiovasculares como HAS, diabetes e dislipidemia. Seus determinantes incluem fatores genéticos, socioeconômicos e comportamentais. A melhora do nível socioeconômico de uma população é acompanhada do aumento de suas taxas de peso, altura e obesidade abdominal.

A obesidade é um excesso no tecido adiposo. No homem o conteúdo da gordura varia de 15% a 18% do peso corporal. A mulher tem uma maior porcentagem de gordura, variando de 20% a 25%.

3.3.4.1 - IMC

O excesso de peso pode ser expresso em várias formas, sendo que o mais útil e sensível é o *Índice de massa corporal (IMC)* ou índice de *Quetelet*. Este consiste em relacionar o peso corporal em quilograma com o quadrado da estatura em metros (m²).

$$\text{IMC} = \text{Peso (kg)} / \text{Altura}^2$$

Em geral, considera-se como obesidade, tanto em homens como em mulheres, quando o IMC é maior que 27 kg/m², o qual corresponde a um excesso de peso maior a 20% de seu peso normal.

As classificações norte-americanas e européias mostram-se na tabela 3.9, prefere-se utilizar o termo Classe IV para a obesidade mórbida, severa ou extrema.

<i>IMC (Kg/m²)</i>	<i>Classe</i>	<i>Risco</i>
20 - 24	0	Normal
25 - 29	I	Baixo
30 - 34	II	Moderado
35 - 39	III	Alto
≥ 40	IV	Muito alto

Tabela 3.10 – Classificação da obesidade com base no IMC correlacionada com o risco.

3.3.4.2 – ÍNDICE DE RELAÇÃO DE GORDURA ENTRE CIRCUNFERÊNCIA DO ABDÔMEN E QUADRIL – WHR.

De acordo com os estudos de Bjornntorpo (1986), existe uma relação entre a distribuição da gordura corporal com a maioria dos problemas de saúde nos seres humanos. Existem relatos de que a obesidade seja responsável pelo aparecimento de 26 doenças crônicas e 15% a 20% das mortes anualmente, atribuídas às *doenças renais, de fígado, artrites, problemas cardíacos, câncer de colo e diabetes*, levando-nos a concluir que em sua maioria, os indivíduos mais magros tendem a viver mais.

Sendo a obesidade um risco no desenvolvimento de doenças crônicas, torna-se de grande importância a localização do acúmulo da gordura corporal. Foram sugeridas classificações de diferentes tipos de obesidade, relacionados com esta localização:

- **Tipos Andróides (tipo Maçã):** Tipo de obesidade caracterizado pelo acúmulo de gordura na região abdominal, localizada tanto entre os órgãos quanto subcutâneo. Conhecida como obesidade de Membros Superiores ou “baixo-ventre”.
- **Tipo Genóides (tipo Pêra):** Tipo de obesidade caracterizado pelo acúmulo de gordura na região glúteo-femoral (quadril, nádegas e pernas). Conhecida como obesidade de membros inferiores.

Através da relação das medidas de circunferência de abdômen e quadril, observou-se que aumento no desenvolvimento de doenças cardíacas em homens está associado com valores acima de 0,90 e em mulheres acima de 0,80 (tab. 3.11).

$$RCQ = \text{Circunferência do Abdômen} / \text{Circunferência do Quadril}$$

<i>Homens</i>	<i>Mulheres</i>	<i>Risco</i>
< 0,90	< 0,80	Baixo
0,90 – 0,95	0,80 – 0,85	Moderado
> 0,95	> 0,85	Alto

Tabela 3.11 – Tabela para Zona de Risco associada com o WHR.
Fonte: Nutrition For Fitness and Sport – WILLIAMS, M.H

3.3.5 - HIPERTENSÃO ARTERIAL SISTÊMICA

A hipertensão arterial é o fator de risco bem estabelecido para o desenvolvimento de todas as manifestações clínicas da aterosclerose. É, portanto, fator predisponente poderoso e comum para o desenvolvimento de doença arterial coronariana, acidentes vasculares cerebrais, doença arterial periférica, insuficiência cardíaca e renal.

Vários estudos longitudinais têm avaliado os riscos das pressões arteriais sistólica e diastólica. O mais conhecido pela sua importância histórica é o estudo de Framingham, que se iniciou em 1949 na cidade de Framingham, Massachussetts, EUA, que envolveu inicialmente, mais de 5.000 indivíduos e que vem publicando seus resultados a intervalos regulares. Após alguns anos, foram identificados os clássicos fatores de risco cardiovascular: hipertensão arterial, tabagismo, diabetes mellitus e hipertrofia ventricular esquerda.

A hipertensão parece estar metabolicamente associada à dislipidemia, intolerância à glicose, obesidade abdominal, hiperinsulinemia, hiperuricemia, entre outros.

No que diz respeito ao sexo, tanto em homens como em mulheres, a doença coronariana aumenta de acordo com a presença de outros fatores de risco. Indivíduos com múltiplos fatores de risco experimentam tipicamente as taxas mais altas de doença arterial coronariana. Um indivíduo, com diabetes, fumante, portador de hipertrofia

ventricular esquerda, com pressão arterial sistólica de 160 mmHg e um nível sérico de HDL-colesterol baixo tem um risco estimado de doença arterial coronariana em 10 anos que excede 55% (independentemente do sexo)(Chaves, 2001).

A história clínica dirigida e o exame físico são os instrumentos essenciais para a avaliação inicial do hipertenso quanto à presença de comprometimento de órgão-alvo, à presença de morbidades e quadro sugestivo de hipertensão secundária.

Na abordagem clínica do hipertenso, duas respostas são fundamentais.

- A primeira se refere ao diagnóstico preciso, se a hipertensão está mesmo presente, uma vez que a variabilidade pressórica é mais intensa com a idade. Deve-se afastar o fenômeno de pseudo-hipertensão. É imprescindível a medida da pressão arterial em ambos os membros superiores (na constatação de grandes diferenças acima de 10mmHg entre os membros, afastar lesão arterial obstrutiva) e na posição de pé, devido à alta frequência de hipotensão ortostática.
- Segunda, investigar a presença de outros fatores de risco associado. Independente do nível pressórico, a presença de comprometimento de órgãos-alvo e/ou condições comórbidas, indicam que o paciente assim afetado tem um pior prognóstico e uma probabilidade substancialmente maior de complicações e morte súbita.

<i>Nível da Pressão Arterial</i>	<i>Classificação</i>
< 120 sistólica e < 80 diastólica	Ideal
< 130 sistólica e < 85 diastólica	Normal
130~139 sistólica ou 86~89 diastólica	Normal-alta
140~159 sistólica ou 90~99 diastólica	Hipertensão Estágio 1
160~179 sistólica ou 100~109 diastólica	Hipertensão Estágio 2
> 110 diastólica ou > 180 sistólica	Hipertensão Estágio 3

Tabela 3.12 – Classificação da Hipertensão Arterial Sistêmica

3.3.6 – ÁCIDO ASCÓRBICO E DOENÇAS CARDIOVASCULARES

Em relação ao ácido ascórbico, popularmente conhecido como vitamina C, este tem sido altamente consumido como suplemento alimentar como forma de prevenir ou combater os resfriados, as doenças cardiovasculares e as neoplasias (Silva *et. al.*, 2000). Sua função antiaterogênica deve-se às suas características antioxidantes, as quais podem reduzir a oxidação da lipoproteína de baixa densidade conhecida como LDL-colesterol (Valkonen & Kuusi, 2000). A proteção completa desta fração parece envolver também a vitamina E, sendo que esta é importante na extinção de radicais produzidos no interior da partícula de LDL-colesterol. Na verdade, a ação da vitamina E parece ser dependente da presença de ácido ascórbico e talvez de outros antioxidantes solúveis (Price, *et al.*, 2001). Desta maneira, o ácido ascórbico pode contribuir para a proteção contra doenças coronarianas em pessoas que ingerem altas quantidades de vitamina C através de frutas e vegetais (Gale *et.al.*, 1993), embora esta vitamina não tenha sido recomendada como um agente redutor de lipoproteínas (Jenner, *et al.*, 2000). Por outro lado, o fato da deficiência de vitamina C promover a formação de lesões ateroscleróticas em porcos da Índia pode suportar a hipótese que a mesma reduz o risco aterogênico. Atualmente existem fracas evidências destes efeitos em humanos (Combs, 1998). Apesar disto, muitos estudos têm relatado que o ácido ascórbico pode aumentar as concentrações de HDL-colesterol (lipoproteína de alta densidade) e diminuir as concentrações de colesterol total (Simon & Hudes, 1999).

3.3.7 – SEDENTARISMO

O sedentarismo constitui fator de risco para a aterosclerose. O exercício físico previne a doença aterosclerótica. O estilo de vida que conte com exercícios físicos e alimentação saudável tem sido destacado como aspecto essencial na prevenção e tratamento de cardiopatia isquêmica. Modificações dietéticas acompanhadas de um programa de exercícios físicos aeróbicos otimizam as mudanças do perfil lipoprotéico plasmático.

Quanto ao impacto isolado do exercício sobre o HDL-C, LDL-C e TG, a literatura tem evidenciado modificações variáveis após programas aeróbicos com mais de quatro semanas de duração em indivíduos sem sobrepeso. O impacto dos programas

regulares de treinamento físico aeróbico tem sido mais expressivo em homens com baixo HDL-C, elevada trigliceridemia e obesidade abdominal.

Tanto a implementação de exercícios de alta como de baixa intensidade, realizados em faixas de 85% a 90% e em torno de 50% a 70% do consumo máximo de oxigênio, respectivamente, podem reduzir os triglicérides e aumentar o HDL-C. Além disso, há melhora da condição cardiorespiratória, melhora da composição corporal, redução da obesidade, do estresse e também do efeito benéfico na pressão arterial (SBC, 2001).

3.4 - PREVENÇÃO

A forma de prevenção mais eficaz é a realizada por meio do combate aos fatores de risco, seja nos indivíduos que ainda não apresentam manifestações de DAC (prevenção primária), seja nos que já a apresentaram (prevenção secundária). Melhor ainda é o combate à instalação dos fatores de risco, em populações em que eles ainda não se desenvolveram, o que é denominado de prevenção primordial. (Bertolami, 2001).

Os fatores modificáveis são, regra geral, consequência do modo de vida. Ter cuidado com o nosso próprio modo de vida não é assim tão difícil. E isso deve começar a fazer-se tão cedo quanto possível, porque a aterosclerose também se instala bastante cedo.

Uma alimentação sã e equilibrada, sem excesso de gorduras e, principalmente, sem excesso de gorduras animais, constitui, assim, um fator importante para conservar a saúde. Para manter a boa forma, o exercício físico diário é obrigatório, bem como a abstenção alcoólica e tabágica. Os acidentes vasculares são também mais frequentes na ansiedade crônica.

Por isso, é conveniente praticar, com frequência de três a seis vezes por semana, sessões de em média 40 minutos, de atividade física aeróbica. A zona alvo do exercício aeróbico deve ficar na faixa de 60% a 80% da frequência cardíaca máxima, observada em teste ergométrico. O componente aeróbico das sessões de condicionamento físico deve ser acompanhado por atividade de aquecimento, alongamento e desaquecimento. É interessante que sejam oferecidas, em média de duas vezes por semana, sessões de exercícios que aprimorem a força e a flexibilidade. (SBC, 2001).

3.5 – DIAGRAMA DE AVALIAÇÃO DE RISCO CORONARIANO.

Os escores de risco de Framingham (ERF), são utilizados como ferramenta de auxílio na estratificação do risco de eventos clínicos coronarianos, onde são calculados o risco absoluto de eventos em 10 anos. São atribuídos pontos para a idade, PAS, PAD, CT, HDL-C, fumo, DM. Após o cálculo dos pontos, deve-se consultar a tabela para ambos os sexos, (anexo 10).

Apresentamos neste capítulo, um diagrama de avaliação de risco coronariano desenvolvido pela “*Second Joint Task Force European and other Societies on Coronary Prevention*”, (Michelson e Moriguchi, 2000)(tab. 3.14).

Analisando a apresentação dos valores no diagrama, alteramos a seqüência de valores do Colesterol, de valor único 150, 200, 250, 300, para faixa de valores, tornando mais clara a interpretação da tabela.

<150
150-200
201-250
251-300
>300


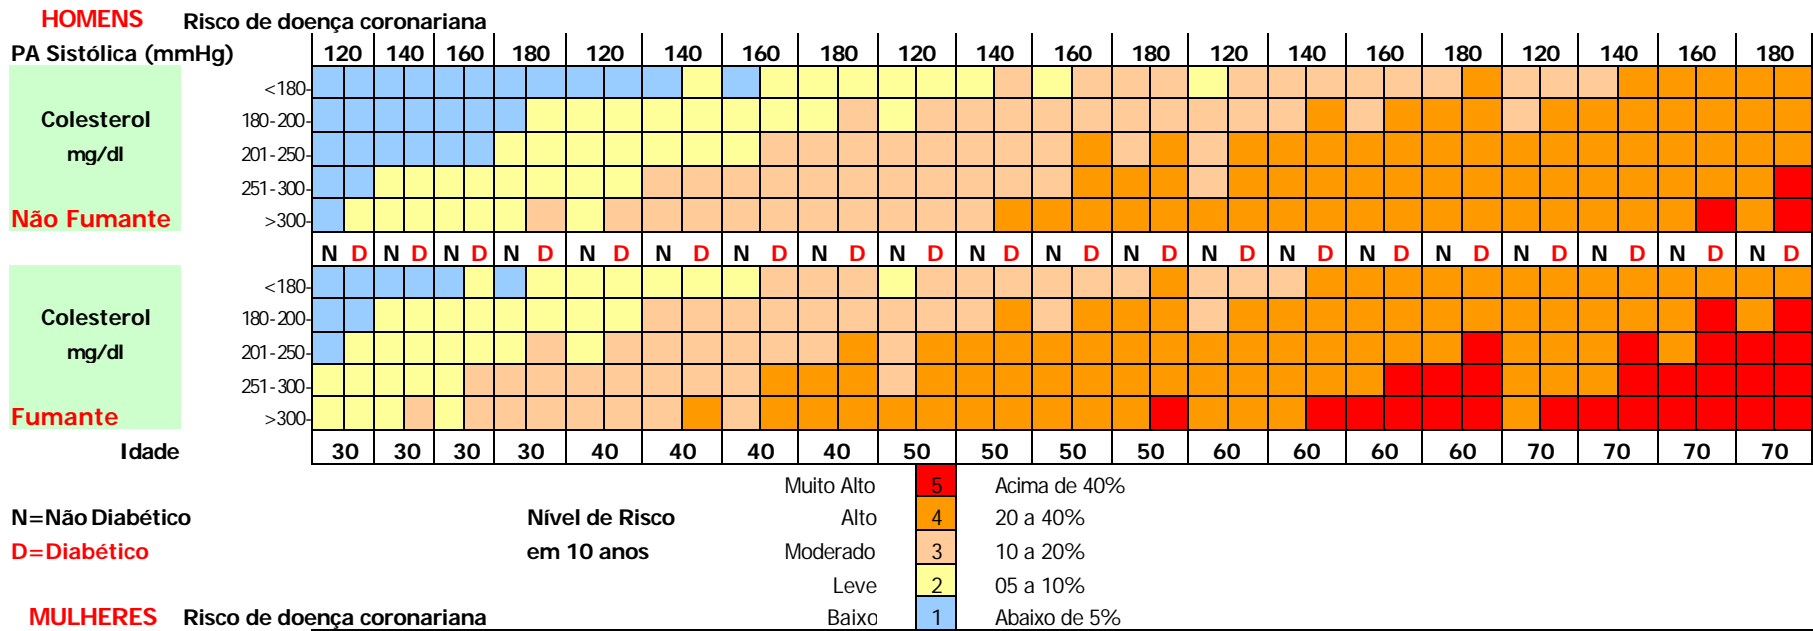
Tabela 3.13 – Distribuição dos valores de referência por faixa na avaliação de risco coronariano.

Os diagramas de risco coronariano para prevenção primária de DAC, servem para:

1. Estimar o risco absoluto de um evento coronariano de uma pessoa durante 10 anos, localizando a tabela para seu gênero (tab. 3.14), idade e se fumante ou não fumante.
2. Encontrar dentro da tabela a célula que possua valor mais próximo à pressão arterial sistólica (mmHg) e colesterol total (mg/dl ou mmol/l)

3. Comparar a cor “nível de cinza” da célula com as encontradas na legenda e encontre o nível do fator de risco.

4. O risco será maior do que indicado no mapa nos seguintes casos:
 - Hiperlipidemia familiar;
 - História familiar de doença cardiovascular prematura;
 - HDL colesterol $< 40\text{mg/dl}$ (1.0 mmol/l);
 - Níveis de triglicérides $> 180\text{ mg/dl}$ (2.0 mmol/l);
 - Quanto mais próxima do próximo grupo etário uma pessoa estiver.



Adaptado das Recomendações do the Second joint Task Force of European and Societies on Coronary Prevention.
European Heart Journal, Atherosclerosis and Journal of Hypertension. 1998.

Tabela 3.14 - Diagrama para avaliação do risco coronariano na prevenção primária da doença arterial coronariana

CAPÍTULO 4

Neste capítulo, são apresentados os métodos e procedimentos utilizados no desenvolvimento desse trabalho na busca da transformação de um banco de dados em uma base de conhecimentos médicos.

4.1 – RESULTADOS LIPÍDICOS PARA AVALIAÇÃO DE RISCO CORONARIANO.

O estudo iniciou com os dados de amostra, fornecidos pela Hotsoft, uma empresa tradicional na área e especializada no desenvolvimento de sistema para automação de Laboratórios de Análises Clínica. A Hotsoft, gentilmente atendendo a uma solicitação, realizou trabalho de pesquisa e seleção em um banco de dados padrão Microsoft Access, de um laboratório de análises clínicas com um total de 659.680 registros de exames para os seguintes itens:

- *Idade*
- *Sexo*
- *Triglicérides (triglicerídios)*
- *Colesterol Total*
- *LDL-Colesterol*
- *HDL-Colesterol*

O resultado do processo de seleção dos dados na pesquisa, apenas 4,7% dos registros atenderam aos critérios de seleção estipulados, totalizando 30.866 registros selecionados.

O arquivo com os resultados dos exames solicitados (tab. 4.1), foi recebido já na formatação delimitada como texto seqüencial.

Idade , Sexo , Triglicérides , Colesterol Total , Colesterol LDL , Colesterol HDL

40 A , masculino , 230 , 188 , ,
 40 A , masculino , 230 , 188 , ,
 63 A , feminino , 95 , 226 , 160 , 47
 63 A , feminino , 95 , 226 , 160 , 47
 63 A , feminino , 95 , 226 , 160 , 47
 63 A , feminino , 95 , 226 , 160 , 47
 48 A , masculino , 324 , 208 , ,
 48 A , masculino , 324 , 208 , ,
 47 A , feminino , 182 , , ,
 57 A , feminino , , 241 , ,
 42 A , feminino , 127 , 196 , 132 , 38
 ...

 Resultados Filtrados: 30866 Registros

Tabela 4.1 – Amostra do arquivo dos resultados para avaliação de lipidograma

4.1.1 – CRIANDO UM BANCO DE DADOS PADRÃO xBASE

Para análise e utilização dos resultados, foi criado um banco de dados padrão xBase (arquivos DBF), utilizado por muitas plataformas de desenvolvimento como dBase, Clipper, FoxBase, Microsoft Fox Pro, Delphi, Visual Basic, C++ Builder, entre muitas outras. Os dados foram importados para o banco de dados, definido com a seguinte estrutura:

Campo	Tamanho	Tipo	Descrição do Campo
IDA	03	Texto	Idade
SEX	01	Texto	Sexo
TG	05	Texto	Triglicéridios
CT	05	Texto	Colesterol Total
HDL	05	Texto	Colesterol HDL
LDL	05	Texto	Colesterol LDL
RIS	01	Texto	Avaliação do Risco

Tabela 4.2 – Estrutura do arquivo banco de dados criado para análise de avaliação de lipidograma

A opção pela utilização de um banco de dados padrão xBase (arquivos DBF), foi devido a natureza interativa do trabalho, aliado ao conhecimento prévio desse padrão de banco de dados. A possibilidade de manipulação das informações contidas no banco de

dados de forma direta, agilizando alguns processos de análise dos dados também influenciou na escolha. Finalmente, o acesso direto do programa Microsoft Excel ao banco de dados padrão xBase para os cálculos, fórmulas e gráficos a serem utilizados durante o estudo, traria algumas vantagens, tais como, rapidez, agilidade na manipulação e intercâmbio direto de dados com a rede neural.

4.1.2 – PRIMEIRA ANÁLISE DOS DADOS

Os dados ao serem analisados visualmente, após o processo de importação para o banco de dados, apresentaram uma formatação e seqüências inadequadas tendo sido necessário um ajuste para compatibilizar com as necessidades do estudo realizado, tais como:

1. Alteração do campo idade, deixando apenas valor, retirando os caracteres.
2. Conversão da informação sexo de caracteres, para um valor numérico (1=feminino, 2=masculino),
3. Eliminar os espaços existentes entre os delimitadores e valores.
4. Muitos registros estavam incompletos contendo apenas resultados de parte dos exames, principalmente de *Colesterol* e *Triglicéridios*, em branco por não terem sido realizados os exames de *LDL Coolesterol* e *HDL Coolesterol*, este critério é adotado por especialidades médicas.
5. O laboratório emitia os resultados sobre 04 (quatro) amostras analisadas de cada exame, ficando os resultados quadruplicados; é importante levar em consideração esse procedimento que é adotado por laboratório que participa do sistema de controle de qualidade laboratorial, garantindo assim, a precisão dos resultados.

Portanto, além dos ajustes efetuados, dos registros quadruplicados foram eliminados três, permanecendo apenas os registros com resultados dos lipídios em todos os itens, dos 30.866 registros iniciais recebidos, permaneceram:

- 2926 resultados de exames completos. (9,5 %) dos quais:
 - 1512 (51,7%) resultados de exames Feminino e
 - 1414 (48,3%) resultados de exames Masculino.

4.1.3 – FUNÇÃO PARA CLASSIFICAÇÃO DA AVALIAÇÃO DE RDC.

O aspecto geral dos *Crítérios de Avaliação de Risco no Diagnóstico Lipídico*, já foi amplamente exposto no Capítulo 3, a partir da definição da estrutura do banco de dados e dos critérios de avaliação de risco, utilizando os valores para CT, HDL, LDL e TG, da tabela 3.3. A tarefa de analisar e avaliar a classificação de risco para 2926 registros de forma manual demandaria muito tempo para ser realizada. Portanto, o desenvolvimento de uma função (*programa interativo sem compilação*) em linguagem dbase, (anexo 5), agilizaria significativamente o processo, para efetuar a classificação do risco de cada indivíduo de acordo com os valores de CT, HDL, LDL e TG, para três faixas de risco, com o cálculo do colesterol HDL, diferenciado para os sexos feminino e masculino.

4.1.3.1 – Resultado da função de classificação de RDC.

A grande demanda de tempo para avaliar a classificação de risco manualmente, foi reduzida há apenas alguns minutos com a utilização da função desenvolvida. Entretanto, é importante ressaltar que o resultado da classificação não foi satisfatório, ficou abaixo do esperado, pois apenas 297 registros, ou seja, 10.2% dos 2926 registros foram classificados pela função, dentro dos critérios estabelecidos.

Como resultado da análise nos dados não classificados, observou-se que, com os valores dos campos do banco de dados, com os valores predefinidos na tabela 3.3, (e também com outro fator relevante), as faixas de avaliação de risco, não poderia atender as diferentes combinações possíveis de valores dos resultados existentes, pois uma ou mais das variáveis, estavam acima ou abaixo dos valores estabelecidos para a faixa de classificação de risco, valores em destaque, como demonstrado na tabela 4.3. Com isso, chegou-se a conclusão de que este método para classificação de avaliação de risco de DAC exigiria fortemente a participação de um profissional médico, que acrescentasse a sua experiência, para determinar a melhor avaliação do fator de risco ou apresentasse outro método existente para avaliar o resultado. O simples domínio de tecnologias computacionais quase sempre não é condição suficiente para se transformar um banco de dados disponível em uma base de conhecimento, principalmente, em se tratando de questões humanas.

IDA	SEX	TG	CT	LDL	HDL	RIS
40	1	117	144	72	48	1
36	2	117	224	148	52	
55	1	93	224	150	55	
30	2	266	262	198	29	3
62	2	227	225	154	36	
49	1	262	140	67	38	
47	1	82	205	138	50	
48	2	138	204	145	32	
35	1	116	155	90	41	1
39	1	63	161	96	52	1
66	2	96	150	84	46	1

Tabela 4.3 – Resultados não classificados pela função de classificação da avaliação de risco

Assim, a solução seria encontrar outro método de classificação mais abrangente, que pudesse envolver todo o conjunto de registros disponíveis.

4.1.3.2 – Determinação da Função logística ou sigmóide para cálculo do RDC.

Uma nova alternativa foi a utilização da conhecida função logística ou sigmóide de forma a apresentar os resultados obtidos a um especialista da área médica para uma validação. Assim sendo, a função que melhor se aproximou dos resultados, no intervalo 0 e 1, sobre os valores dos resultados dos exames foi determinada pela expressão:

$$f(x) = \frac{1}{1 + \exp^{-a(x/10)}}$$

Equação 4.1 – Fórmula da função logística para classificação da avaliação de risco

A fórmula da função logística ou sigmóide, aplicada aos valores dos resultados lipídicos, gerando valores entre 0 e 1 é mostrada na tabela 4.4. O valor do limite inferior foi estabelecido em 200 (valor normal de CT) e o superior em 240 (valor limítrofe de CT).

Original	Função sigmóide
200	0.002472623
201	0.003334807
202	0.004496273
238	0.995503727
239	0.996665193
240	0.997527377

Tabela 4.4 – Resultados da função logística ou sigmóide aplicada sobre resultados de colesterol total

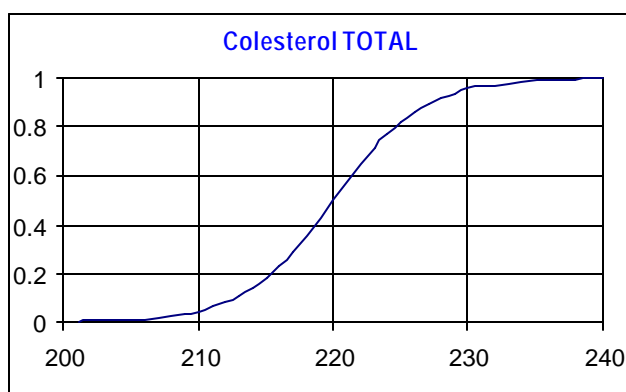


Figura 4.1 – Função logística sigmóide para avaliação de risco CT, LDL e TG.

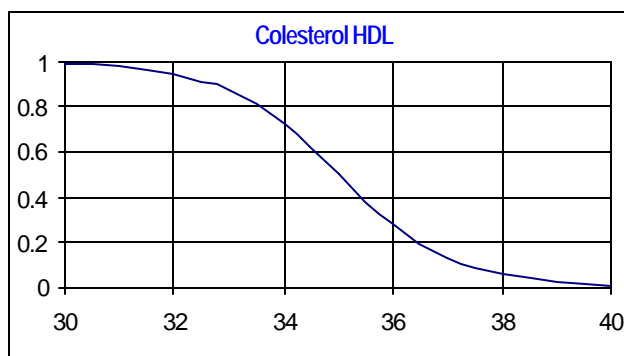


Figura 4.2 – Função logística sigmóide para avaliação de risco HDL.

A seguir serão apresentadas as expressões utilizadas sobre os valores de resultados lipídicos. Os valores de alfa foram ajustados para melhor se aproximarem dos valores 0 e 1 sobre os valores originais:

- Colesterol total $1 / (1 + \text{EXP}(- 3 * (- 2 + (\text{CT} - 200) / 10)))$
- LDL-colesterol $1 / (1 + \text{EXP}(- 2 * (- 2.5 + (\text{LDL} - 100) / 10)))$
- HDL-colesterol $1 / (1 + \text{EXP}(9.5 * (-0.5 + (\text{HDL} - 30) / 10)))$
- Triglicérides $1 / (1 + \text{EXP}(- 2 * (- 2.5 + (\text{TG} - 150) / 10)))$

Expressão 4.2 – Expressão logística aplicada aos resultados dos lipídios

4.1.3.3 – Utilização da função logística sigmóide determinada.

Neste método, os valores originais de CT, HDL, LDL e TG, foram substituídos pelos valores resultantes da aplicação da função sigmóide. Com esta técnica a classificação para avaliação do perfil Lipídico, foi a soma dos valores obtidos pela função logística sigmóide. Dessa forma, os resultados ficaram entre 0 e 4. O valor de um resultado normal (próximo a 200), corresponderia a um valor próximo a 0. Do mesmo modo, um valor de resultado próximo do limite superior (240) corresponderia a um valor próximo a 1, exceto para o HDL, que tem a sua função inversa, sendo seus valores entre 1 e 0, conforme os valores destacados demonstrados na tab. 4.5.

VALORES ORIGINAIS				VALORES DA FUNÇÃO SIGMOIDE				FAIXA DE
CT	HDL	LDL	TG	CT	HDL	LDL	TG	RISCO
207	56	141	49	0.01984	2.17E-09	0.960834	1.14E-11	2.0
232	66	155	57	0.973403	1.62E-13	0.997527	5.63E-11	3.0
262	41	176	225	0.999997	0.003335	0.999963	0.999955	4.0
219	68	129	110	0.425557	2.43E-14	0.689974	2.26E-06	2.1
206	56	133	84	0.014774	2.17E-09	0.832018	1.25E-08	1.8
186	41	128	80	3.72E-05	0.003335	0.645656	5.6E-09	1.6
235	39	164	164	0.989013	0.021881	0.99959	0.09975	3.1
233	55	150	139	0.98016	5.6E-09	0.993307	0.000746	3.0
193	47	125	106	0.000303	1.12E-05	0.5	1.02E-06	1.5

Tabela 4.5 – Valores originais e da função logística sobre os resultados lipídicos.

Essa experiência não apresentou resultados compatíveis com os métodos clássicos de avaliação, pois apenas os valores lipídicos laboratoriais (CT, HDL, HDL e TG, da tabela 4.5), apresentaram uma diferença média de 56% na avaliação dos resultados dos 113 indivíduos da amostra (ver item 4.1.4.1) utilizada neste estudo, como demonstrado no anexo 4.

4.1.4 – SUBMETENDO OS RESULTADOS DA FUNÇÃO A ANÁLISE DE UM PROFISSIONAL.

Através de informação obtida junto a dois profissionais médicos, sobre a forma de avaliação de resultados lipídicos, constatou-se que apenas o uso dos resultados do CT e TG, desconsiderando normalmente os resultados de HDL-c e LDL-c. Entretanto, ambos sugeriram que fosse procurado um profissional da área de cardiologia, onde poderia-se obter maiores informações sobre o assunto. A Dra. Carmen², integrante do grupo de estudos sobre a dislipidemia do SASC/HU, foi indicada.

4.1.4.1 – Consulta médica ou consulta técnica?

A primeira reunião com a Dra. Carmen mudou radicalmente o rumo da pesquisa. Informações extremamente importantes estavam sendo simplesmente desconsideradas. Com a utilização apenas das variáveis: Idade, sexo, CT, HDL-c, LDL-C e TG, de forma isolada, sem um histórico do paciente e histórico familiar, além de outros itens importantes como: hipertensão arterial, diabetes, tabagismo, obesidade, de maneira que não era possível avaliar e classificar um risco de doença arterial coronariana. De qualquer forma, esses dados serviriam apenas como estudo estatístico e de pesquisa, mas sem um valor clínico efetivo. Entretanto, dentro do SASC, há o NIPEAD (*Núcleo Interdisciplinar de Pesquisa, Ensino e Assistência à Dislipidemia*), que mantém um estudo e acompanhamento longitudinal de 113 indivíduos, todos funcionários do HU, os quais tinham os valores do perfil lipídico, da massa corporal (altura e peso) e das medidas de cintura e quadril (dados antropométricos). Acrescentou-se assim, dois novos fatores de riscos (IMC e ICQ), além do risco coronariano (RDC), que seriam pois avaliados e calculados. Estes dados e cálculos seriam obtidos dentro de uma metodologia de pesquisa e avaliação laboratorial com controle de qualidade,

prontificando-se a fornecer a base de dados, bibliografia, bem como, a auxiliar na análise da avaliação da classificação dos riscos IMC, ICQ e DAC, e dos resultados finais obtidos pelo estudo.

A partir de então a pesquisa mergulhou no mundo da dislipidemia em definitivo, através do *Resumo das III Diretrizes Brasileiras sobre Dislipidemias e Diretrizes de Prevenção da Aterosclerose*, da Sociedade Brasileira de Cardiologia (SBC-2001), assunto este objeto do presente estudo.

Um fato interessante é que essas pesquisas hoje não estão mais sob a alçada de uma única especialidade, mas na integração de diferentes áreas e profissionais. Busca-se envolver opiniões de todos aqueles que estão ligados, direta ou indiretamente, no estudo, na prevenção dos fatores de risco de doenças cardiovasculares, em especial das doenças arteriais coronarianas.

4.2 – NOVOS DADOS DE AMOSTRA UTILIZADOS NO ESTUDO

Os dados desta nova etapa da pesquisa foram coletados em maio de 2001, nas dependências do Hospital Universitário (HU) da UFSC, pelo NIPEAD/HU/UFSC. Todos os indivíduos participantes desta pesquisa eram funcionários do HU. Além dos procedimentos normais de coleta das amostras, os dados foram registrados em fichas numeradas sequencialmente, contendo as informações de cada indivíduo, pertinentes a diferentes áreas como, *sócio-econômico, médica, nutrição, psicologia, educação física*, que abrangem o estudo em sua primeira etapa.

Este estudo prosseguirá acompanhando esses indivíduos, em etapas anuais com coleta de exames, complementando e analisando as informações, como ocorre em outros estudos de grande porte como o da cidade de Framingham (Michigan - EUA), que acompanha a terceira geração da população pesquisada daquela cidade, e o PROCAM, estudo do coração de Münster na Alemanha, com 23.616 indivíduos sendo acompanhados, e iniciou em 1979 (Bertolami, 2001).

² Dra. Carmen Dolores de Araújo Waltrick – Cardiologista NIPEAD/SASC/HU e Especialista em Medicina Nuclear.

4.2.1 – ITENS DAS INFORMAÇÕES CONTIDAS NO FORMULÁRIO DE AVALIAÇÃO.

I - Dados Gerais

Identificação

Situação sócio-econômica.

II - Dados Médicos

Interrogatório sistemático

Exame físico

Medicamentos em uso/dose

Avaliação dos fatores de risco

Classificação de Risco

Prevenção

Objetivo do Tratamento

III - Lista de exames complementares 1ª consulta

IV - Exames complementares

V – Dados Nutricionais

História alimentar

Doença pregressa

Dia alimentar

Avaliação Nutricional

Sinais Clínicos

Diagnóstico Nutricional

Conduta Dietoterápica

VI – Dados da Psicologia

VII – Dados da Educação Física

Anamnesia Clínica

Correção Postural

Composição Corporal

Aspecto Hemodinâmico

Sistema Aeróbico

 Teste de Cooper

 Escala de percepção subjetiva de esforço proposta por Borg

Aspectos Neuromuscular

 Flexibilidade

 Força / Resistência Muscular

VIII – Retornos

 Data – Nome do Profissional – Especialidade.

4.2.2 – MÉTODOS E PROCEDIMENTOS UTILIZADOS NA ANÁLISE DE RESULTADOS DA COLETA.

Cada profissional em sua especialidade realizou a coleta de material, e as informações necessárias ao preenchimento do formulário, para posterior análise.

As análises laboratoriais foram executadas pelo setor de Bioquímica do Laboratório de Análises Clínicas do Hospital Universitário (HU). Para a verificação dos níveis lipídicos, foi utilizado a punção capilar e análise colorimétrica, realizada pelo aparelho Cholestech L.D., cedido pela Sanofi–Oroxadim. Para a coleta das medidas antropométricas foi usado o protocolo do Laboratório de Avaliação Física do CDS – UFSC. O perfil lipídico foi definido pelas determinações do: colesterol total (CT) e triglicerídios (TG) utilizando métodos enzimático - colorimétrico automatizado; a fração HDL-colesterol (HDL), pelo método de precipitação seletiva acoplado a dosagem por método enzimático colorimétrico automatizado e a fração LDL-colesterol (LDL) foi obtida por cálculo utilizando a fórmula de Friedewald.

O aparelho utilizado para todas as determinações automatizadas acima descritas foi o DADE Dimension ® AR/Clinical Chemistry System (DADE International Inc. / DADE Behring Inc., Newark, DE – USA). Os Kits usados para as determinações acima foram fornecidos pela DADE Chemistry System Inc. (DADE Behring Inc., Newark, DE – USA).

Todas essas determinações foram executadas utilizando-se o programa de Controle de Qualidade da Control-Lab (Rio de Janeiro-Brasil) da Sociedade Brasileira de Patologia Clínica e o programa PNCQ da Sociedade Brasileira de Análises Clínicas.

4.2.3 – CLASSIFICAÇÃO DOS DADOS DA AMOSTRA

Os dados da amostra populacional, objeto do presente estudo, são um conjunto de informações obtidos por interrogação pessoal e analisados por processos laboratoriais, sendo a população constituída de 113 indivíduos, onde 24 eram homens e 89 eram mulheres, com idade entre 18 a 64 anos. As informações sobre perfil lipídico, dislipidemias, massa corporal e antropométrico, para a área de cardiologia foram obtidos a partir da ficha individual e tabulados pela cardiologista do NIPEAD/SASC/HU/UFSC, Carmen Dolores de Araújo Waltrick, a tabela 4.6., contém as informações relevantes para este estudo de cada indivíduo, (o nome foi retirado da tabela, a fim de preservar a identidade do participante do estudo):

n.	IDA	SEXO	FC	CC	CQ	EST	MC	CT	HDL	LDL	TG	VLDL	CT/HDL	IMC
1	44	F	80	85	113	1.62	74.800	207	56	141	49	10	3.7	28.50
2	43	F	68	80	102	1.56	62.500	232	66	155	57	11	3.5	25.68
3	55	F	94	89	94	1.57	60.500	262	41	176	225	45	6.4	24.54
4	48	F	74	77	103	1.60	62.800	219	68	129	110	22	3.2	24.53
5	55	F	80	87	107	1.58	65.500	206	56	133	84	17	3.7	26.24
6	43	F	72	98	122	1.74	88.000	186	41	128	80	16	4.5	29.07
7	38		76	117	119	1.79	109.500	235	39	164	164	33	6.1	34.17
8	64	F	64	97	105	1.59	70.000	233	55	150	139	28	4.2	27.69

Tabela 4.6 – Valores de referência da tabela originalmente tabulada.

A seguir apresentamos o significado do conteúdo das siglas das colunas da tabela de dados:

- N., número sequencial da ficha de identificação.
- Ida, idade do participante
- Sexo, F para Feminino e célula vazia para Masculino.
- FC, frequência cardíaca.
- CC, medida da cintura.

- CQ, medida do quadril.
- EST, estatura (altura).
- MC, massa corporal (peso).
- CT, colesterol total.
- HDL colesterol
- LDL colesterol
- TG, triglicerídios.
- VLDL colesterol
- CT/HDL, índice de risco composto pelo colesterol total/HDL-colesterol.
- IMC, índice de massa corporal ou índice de Quetelet.

4.2.4 – ALTERAÇÕES NA TABELA DE CLASSIFICAÇÃO DOS DADOS DA AMOSTRA

Os dados do estudo contido da tabela original foram alterados visando obter uma padronização que pudesse facilitar sua utilização estatística e com redes neurais.

Também foram incluídos novos itens, de real importância na avaliação do risco de DAC:

- FU (Tabagismo ou Fumante)
- DM (Diabetes Mellitus).
- HAS (Hipertensão Arterial).
- ICQ (Índice de cintura e quadril)

4.2.5 – CLASSIFICAÇÃO DE AVALIAÇÃO DOS RISCOS DE DOENÇAS

A classificação da avaliação do risco sobre o índice de massa corporal (RMC), foram definidos de acordo com os índices apresentados na tabela 3.10. Já o risco de circunferência do abdômen versus quadril (RCQ), com os índices estabelecidos na tabela 3.11.

Para avaliação de risco de doença arterial coronariana (RDC), foram utilizados os diagramas de avaliação de risco coronariano desenvolvido pela “Second Joint Task

Force European and other Societies on Coronary Prevention”, (Michelson e Moriguchi, 2000), (tab. 3.14).

No estudo e pesquisa para o levantamento das informações complementares, na ficha individual e a determinação da avaliação dos índices de risco (IMC, ICQ, RDC), de cada indivíduo, novamente contou-se com a importante colaboração da cardiologista do NIPEAD/HU/UFSC, Carmen Dolores de Araújo Waltrick. A tabela completa do exemplo da tabela 4.7 encontra-se no anexo 1.

n.	IDA	SE	CT	HDL	LDL	TG	CT/HDL	IMC	ICQ	FU	DM	HAS	RCQ	RMC	RDC
1	44	1	207	56	141	49	3.7	28.50	0.75	0	0	1	1	1	1
2	43	1	232	66	155	57	3.5	25.68	0.78	0	1	1	1	1	2
3	55	1	262	41	176	225	6.4	24.54	0.95	0	0	2	3	0	3
4	48	1	219	68	129	110	3.2	24.53	0.75	0	1	2	1	0	2
5	55	1	206	56	133	84	3.7	26.24	0.81	0	1	1	2	1	2
6	43	1	186	41	128	80	4.5	29.07	0.80	0	1	2	2	1	2
7	38	2	235	39	164	164	6.1	34.17	0.98	1	0	2	3	2	3
8	64	1	233	55	150	139	4.2	27.69	0.92	0	2	1	3	1	3

Tabela 4.7– Valores de referência da tabela atualizada.

A tabela 4.7, com os novos itens e valores de referência, bem como, a determinação da avaliação dos riscos, os novos itens são:

- ICQ índice de cintura quadril;
- FU tabagismo/Fumante (0 = Não e 1 = Sim);
- DM diabetes melittus (0 = Não Sabe, 1 = Não e 2 = Sim);
- HAS hipertensão arterial (1 = Não e 2 = Sim);
- RCQ classificação do risco cintura/quadril;
- RMC classificação do risco massa corporal;
- RDC classificação de risco coronariano.

4.3 – PROCESSO DE AVALIAÇÃO DE ÍNDICES E RISCOS

A partir do estudo do volume de dados da amostra populacional, (113 indivíduos), foram gerados os seguintes índices e riscos:

- **Índices**
 - a. CT/HDL
 - b. IMC
 - c. ICQ

- **Riscos**
 - a. RMC
 - b. RCQ
 - c. RDC

Para atingir esse objetivo, ou seja, a estratificação do risco coronariano, inúmeras tabelas foram pesquisadas. As informações extraídas de cada ficha individual, foram combinada com seis variáveis diferentes e cinco cores para se obter a avaliação de risco de doença arterial coronariana (DAC). Esse processo, além de envolver uma grande massa de dados também exigiu o envolvimento de um profissional da área médica de cardiologia.

Toda essa dificuldade encontrada motivou a criação de um *software* que, através de uma plataforma de desenvolvimento simples, agiliza toda a organização dos dados, efetuando o cálculo dos índices e riscos automaticamente.

4.3.1 – MÓDULOS DO PROJETO DO SOFTWARE DESENVOLVIDO

O software foi desenvolvido com banco de dados padrão xBase, em linguagem de programação *CA-Clipper*, e permite exportação de dados nos formatos TXT (texto), SDF (*Standard Data Format* ou Formato Padrão de Dados) e DBF (*Data Base File*), este é o mesmo formato que se encontra os arquivos de dados.

O sistema conta com os seguintes módulos no projeto:

TABELA DE ÍNDICES

CLASSE IMC(Kg/m ²)		Risco	Zona de Risco ICQ				
0	99-99	9	Baixo		Masculino	Feminino	R
I	99-99	9	Moderado	Alto	> 9.99	> 9.99	9
II	99-99	9	Médio	Moderado	9.99-9.99	9.99-9.99	9
III	99-99	9	Alto	Baixo	< 9.99	< 9.99	9
IV	>=99	9	Muito Alto				

3. Relatório

```

1          2          3          4          5          6          7          8
12345678901234567890123456789012 345678901234567890123456789012345678901234567890123456789
01 N I P E A D / S A S C / H U          L I S T A G E M          Pag:9999 02/05/2002
02 Avaliação de Risco de DAC          DOS PARTICIPANTES          RIS_R001
03 -----
04 IDEN  IDA S CIN QUA ESTA  PESO  CT  HDL  LDL TG CT/HDL F D H  IMC  ICQ  RMC  RCQ  RC
05 -----
06 XXXXX 999 9 999 999 9999 999999 9999 9999 9999 9999 9999 9 9 9 99999 99999 9999 9999 9999
07
08
09
10

```

4.3.2 – CONVERSÃO DA TABELA DE AVALIAÇÃO RDC.

Para a compatibilizar os dados de entrada do sistema com os valores pré-definidos da tabela 3.14, foram utilizadas funções para discretizar as variáveis como: *idade*, *colesterol (CT)*, *pressão arterial (PAS)*, *diabetes (DM)*.

É importante ressaltar que a tabela 3.14 avalia a classificação dos cinco riscos por cores. Para o sistema desenvolvido, esse método, precisou ser transformando em valores numéricos a partir da combinação do conjunto de variáveis: *CT*, *PAS*, *DB*, *fumo*, *idade*, *sexo*. Esse processo resultou em uma nova tabela de riscos com 800 registros, que são as combinações possíveis dos valores da tabela original.

SEQ	IDA	SEX	FUM	DM	PAS	CT	RDC
0001	30	1	0	1	120	150	1
0002	30	1	0	2	120	150	1
0003	30	1	1	1	120	150	1
0004	30	1	1	2	120	150	1
0005	30	1	0	1	120	200	1
0006	30	1	0	2	120	200	1
0007	30	1	1	1	120	200	1
0008	30	1	1	2	120	200	1
0009	30	1	0	1	120	250	1
0010	30	1	0	2	120	250	1
0011	30	1	1	1	120	250	1
0012	30	1	1	2	120	250	1
0013	30	1	0	1	120	300	1
0014	30	1	0	2	120	300	1
0015	30	1	1	1	120	300	1
0016	30	1	1	2	120	300	1
0017	30	1	0	1	120	301	1
0018	30	1	0	2	120	301	1
0019	30	1	1	1	120	301	1
0020	30	1	1	2	120	301	1

Tabela 4.8 – Tabela de riscos de DAC combinados no banco de dados.

4.3.3 – TELA DE CADASTRO COM AVALIAÇÃO DE RISCO

A figura da tela de cadastro (*entradas das informações*) fig. 4.3, apresenta os valores digitados, os valores resultantes de fórmula calculada, os valores já discretizados referente aos valores digitados (1), o registro que atendeu a critério de pesquisa (2), bem como, o valor do índice de risco de doença coronária (RDC), já avaliado (3).

CADASTRO			
Número... [ID]	00033		1
Idade.....	60	Sexo.... [12]	2
Cintura... [CC]	76	Quadril. [CQ]	95
Estatura... [M]	1.81	Peso.... [Kg]	67.00
CT.....	161	HDL.....	46
LDL.....	106	TG.....	49
CT/HDL... [FC]	3.50		
Fumo..... [01]	0	DM..... [012]	1
PAS... [120 180]	110	HAS..... [12]	2

IMC..... [FC]	20.45	ICQ..... [FC]	0.80
RMC..... [FC]	0.00	RCQ..... [FC]	1.00

RDC..... [DAC]	0.00	[0.00 %]	
Inclui	F3, F4, F9		

Risco: 3 - Moderado
Entre 10% e 20%
NR 10 Anos

3 Pressione ←

2

ID	S	F	D	HNS	CT
VDAC 60	2	0	1	120	200 R
0645 60	2	0	1	120	200 3

Figura 4.3 – Tela de entrada de dados com o resultado da avaliação de risco.

4.4 – ANÁLISES ESTATÍSTICA DOS RESULTADOS.

Após a avaliação das classificações de risco por índice de massa corporal, índice de risco cintura/quadril e índice de risco coronariano, os componentes do quadro de dados da amostra populacional do estudo estavam determinados e esta fase do estudo concluída.

A importância dos resultados estatísticos da amostra obtidos, do ponto de vista clínico, são de extrema importância para o controle das dislipidemias e a prevenção da doença aterosclerótica. Esses valores numéricos e percentuais, podem determinar medidas preventivas para diminuir os fatores de risco (FR), identificando indivíduos com *alto risco* para o desenvolvimento de doença arterial coronariana (DAC).

Esse fato justificou a próxima meta da pesquisa que de certa forma não estava previsto no trabalho.

4.4.1 – Quantificação dos dados

Este estudo analisa os valores de referências de resultados de pesquisa direta e procedimentos laboratoriais, de 113 indivíduos, sendo 89 do sexo feminino (79%) e 24 do sexo masculino (21%), todos funcionários do HU, conforme esta demonstrado nos gráficos abaixo.




Gráfico 4.1 – Número dos dados da amostra geral e por sexo.





Gráfico 4.2 – Percentual dos dados da amostra por sexo.

Gráfico 4.3 – Percentual por risco coronariano.

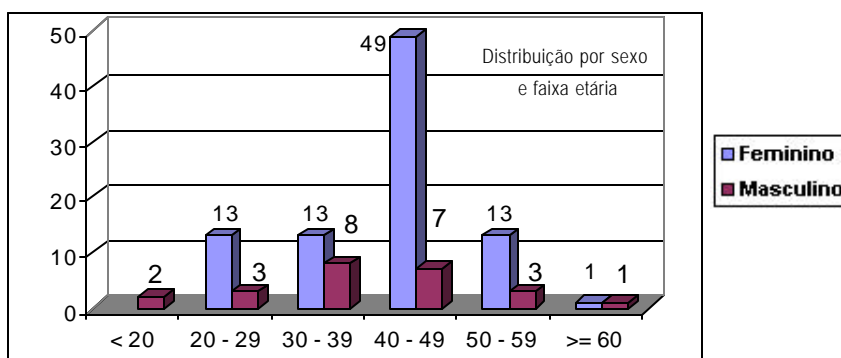


Gráfico 4.4 – Distribuição dos dados por faixa etária e sexo.

A seguir são apresentados as funções estatísticas utilizadas e os valores obtidos com os dados da amostra populacional, tabela 4.9.

TIPO	IDA	SEX	CT	HDL	LDL	TG	CTHDL	IMC	ICQ	FU	DM	HAS	RCQ	RMC	RDC
Desvio	9.83	0.41	37.6	15	40.91	53	1.43	4.88	0.07	0.4	0.6	0.47	0.69	0.89	0.82
Mínimo	18	1	99	25	0	44	0	16.36	0.65	0	0	1	1	0	1
Média	41.0	1.2	186	52.7	107.2	98.1	3.7	26.02	0.8	0.2	0.7	1.3	1.6	0.8	1.7
Máximo	64	2	306	100	184	324	7.8	38.95	0.98	1	2	2	3	3	4
Variância	97.48	0.17	1429	226	1689	2834	2.06	24.00	0.0049	0.1	0.4	0.22	0.48	0.80	0.68
Distorção	-0.47	1.43	0.15	0.84	-0.92	1.45	0.06	0.63	0.13	1.9	0.1	0.79	0.82	1.064	0.91
Moda	48	1	189	56	0	44	3.7	22.94	0.77	0	1	1	1	0	1

Tabela 4.9 – Estatísticas básicas dos resultados e avaliação de risco.

4.4.2 – Distribuição dos dados por faixa etária e quantificação pela classificação dos riscos.

Uma análise mais detalhada com os dados da amostra é apresentada através da classificação de faixa etária, e subdividida por quantificação das variáveis de influência e a avaliação dos riscos de *índice de massa corporal*, *cintura/quadril* e *risco de doença coronária*. As tabelas de 4.10 a 4.18, apresentam os valores quantificados e em percentuais do conjunto de dados da amostra.

- ID - Idade
- FU – tabagismo (fumante) *0=não, 1=sim*
- DM – diabetes melittus *0=não sabe, 1=não, 2=sim*
- HAS – hipertensão arterial *1=não, 2=sim*
- CT – colesterol total *0=ótimo (normal), L=limítrofe (aceitável),
A=alterado (elevado)*
- RMC – risco massa corporal *0=normal, 1=baixo, 2=moderado, 3=alto,
4=muito alto*
- RCQ – risco cintura quadril *1=baixo, 2=moderado, 3=alto*
- RDC – risco doença coronária *1=baixo, 2=moderado, 3=alto,
4=muito alto*

TOTAL		FATORES DE RISCO										RISCOS												
Faixa de Idade	ID	FU		DM			HAS			CT				RMC				RCQ			RDC			
		0	1	0	1	2	1	2	0	L	A	0	1	2	3	4	1	2	3	1	2	3	4	
< 20	2	2		2			1	1	2			2				2			2					
20 – 29	16	15	1	7	9	0	15	1	15	1		11	4	1		13	3		16					
30 – 39	21	16	5	10	11	0	18	3	15	5	1	10	9	2		14	5	1	18	2	1			
40 – 49	56	47	9	16	36	4	34	22	38	15	3	18	24	9	5	28	22	7	19	30	7			
50 – 59	16	13	3	5	7	3	8	7	8	3	4	6	4	2	3	4	7	4	2	4	8	1		
>= 60	2	2		1	2	1	2	2	1			1	2			1	1	1				3		
	113	95	18	38	66	9	77	36	80	25	8	48	43	14	8	0	62	38	13	57	36	19	1	

Tabela 4.10 – Quantificação geral por faixa etária dos FR e riscos.

TOTAL		FATORES DE RISCO									
Faixa de Idade	ID	FU		DM			HAS		CT		
		0	1	0	1	2	1	2	0	L	A
< 20	1.8%	1.8%			1.8%		0.9%	0.9%	1.8%		
20 – 29	14.2%	13.3%	0.9%	6.2%	8.0%		13.3%	0.9%	13.3%	0.9%	
30 – 39	18.6%	14.2%	4.4%	8.8%	9.7%		15.9%	2.7%	13.3%	4.4%	0.9%
40 – 49	49.6%	41.6%	8.0%	14.2%	31.9%	3.5%	30.1%	19.5%	33.6%	13.3%	2.7%
50 – 59	14.2%	11.5%	2.7%	4.4%	6.2%	2.7%	7.1%	6.2%	7.1%	2.7%	3.5%
>= 60	1.8%	1.8%			0.9%	1.8%	0.9%	1.8%	1.8%	0.9%	
	100%	84.1%	15.9%	33.6%	58.4%	8.0%	68.1%	31.9%	70.8%	22.1%	7.1%

Tabela 4.11 – Percentuais gerais por faixa etária dos fatores de risco

TOTAL		RISCOS											
Faixa Idade		RMC				RCQ				RDC			
		0	1	2	3	4	1	2	3	1	2	3	4
< 20	1.8%						1.8%			1.8%			
20 – 29	9.7%	3.5%	0.9%				11.5%	2.7%		14.2%			
30 – 39	8.8%	8.0%	1.8%				12.4%	4.4%	0.9%	15.9%	1.8%	0.9%	
40 – 49	15.9%	21.2%	8.0%	4.4%			24.8%	19.5%	6.2%	16.8%	26.5%	6.2%	
50 – 59	5.3%	3.5%	1.8%	2.7%			3.5%	6.2%	3.5%	1.8%	3.5%	7.1%	0.9%
>= 60	0.9%	1.8%					0.9%	0.9%	0.9%			2.7%	
	42.5%	38.1%	12.4%	7.1%	0.0%	54.9%	33.6%	11.5%	50.4%	31.9%	16.8%	0.9%	

Tabela 4.12 – Percentuais gerais por faixa etária das avaliações de risco.

FEMININO		FATORES DE RISCO										RISCOS														
Faixa de Idade	ID	FU			DM			HAS			CT				RMC				RCQ				RDC			
		0	1	0	1	2	1	2	O	L	A	0	1	2	3	4	1	2	3	1	2	3	4			
< 20																										
20 – 29	13	12	1	6	7	0	12	1	12	1		9	3	1			10	3		13						
30 – 39	13	10	3	5	8	0	12	1	9	3	1	7	5	1			8	4	1	13						
40 – 49	49	41	8	14	31	4	30	19	34	13	2	18	20	6	5		25	18	6	18	26	5				
50 – 59	13	11	2	3	7	3	6	7	6	3	4	6	3	1	3		4	5	4	2	3	7	1			
>= 60	1	1				1	1			1									1			1				
	89	75	14	28	53	8	61	28	61	21	7	40	32	9	8	0	47	30	12	46	29	13	1			

Tabela 4.13 – Quantificação da amostra feminina por faixa etária, FR e riscos.

FEMININO		FATORES DE RISCO									
Faixa de Idade	ID	FU		DM			HAS		CT		
		0	1	0	1	2	1	2	O	L	A
< 20											
20 – 29	15%	13.5%	1.1%	6.7%	7.9%		13.5%	1.1%	13.5%	1.1%	
30 – 39	15%	11.2%	3.4%	5.6%	9.0%		13.5%	1.1%	10.1%	3.4%	1.1%
40 – 49	55%	46.1%	9.0%	15.7%	34.8%	4.5%	33.7%	21.3%	38.2%	14.6%	2.2%
50 – 59	15%	12.4%	2.2%	3.4%	7.9%	3.4%	6.7%	7.9%	6.7%	3.4%	4.5%
>= 60	1%	1.1%				1.1%	1.1%			1.1%	
	100%	84.3%	15.7%	31.5%	59.6%	9.0%	68.5%	31.5%	68.5%	23.6%	7.9%

Tabela 4.14 – Percentuais da amostra feminina por faixa etária dos fatores de risco

FEMININO		RISCOS												
Faixa Idade		RMC				RCQ				RDC				
		0	1	2	3	4	1	2	3	1	2	3	4	
< 20														
20 – 29		10.1%	3.4%	1.1%			11.2%	3.4%		14.6%				
30 – 39		7.9%	5.6%	1.1%			9.0%	4.5%	1.1%	14.6%				
40 – 49		20.2%	22.5%	6.7%	5.6%		28.1%	20.2%	6.7%	20.2%	29.2%	5.6%		
50 – 59		6.7%	3.4%	1.1%	3.4%		4.5%	5.6%	4.5%	2.2%	3.4%	7.9%	1.1%	
>= 60			1.1%						1.1%			1.1%		
		44.9%	36.0%	10.1%	9.0%	0.0%	52.8%	33.7%	13.5%	51.7%	32.6%	14.6%	1.1%	

Tabela 4.15 – Percentuais da amostra feminina por faixa etária e avaliações de risco

MASCULINO		FATORES DE RISCO										RISCOS											
Faixa de Idade	ID	FU		DM			HAS			CT		RMC				RCQ			RDC				
		0	1	0	1	2	1	2	0	L	A	0	1	2	3	4	1	2	3	1	2	3	4
< 20	2	2		2			1	1	2			2				2			2				
20 – 29	3	3		1	2		3		3			2	1			3			3				
30 – 39	8	6	2	5	3		6	2	6	2		3	4	1		6	1	1	5	2	1		
40 – 49	7	6	1	2	5		4	3	4	2	1		4	3		3	4		1	5	1		
50 – 59	3	2	1	2			2		2				1	1			2			1	1		
>= 60	1	1			1	1		2	2			1	1			1	1					2	
	24	20	4	10	13	1	16	8	19	4	1	8	11	5	0	0	15	8	1	11	8	5	0

Tabela 4.16 – Quantificação da amostra masculina por faixa etária, FR e riscos.

MASCULINO		FATORES DE RISCO									
Faixa de Idade	ID	FU		DM			HAS		CT		
		0	1	0	1	2	1	2	0	L	A
< 20	8.3%	8.3%			8.3%		4.2%	4.2%	8.3%		
20 – 29	12.5%	12.5%		4.2%	8.3%		12.5%		12.5%		
30 – 39	33.3%	25.0%	8.3%	20.8%	12.5%		25.0%	8.3%	25.0%	8.3%	
40 – 49	29.2%	25.0%	4.2%	8.3%	20.8%		16.7%	12.5%	16.7%	8.3%	4.2%
50 – 59	12.5%	8.3%	4.2%	8.3%			8.3%		8.3%		
>= 60	4.2%	4.2%			4.2%	4.2%		8.3%	8.3%		
	100%	83.3%	16.7%	41.7%	54.2%	4.2%	66.7%	33.3%	79.2%	16.7%	4.2%

Tabela 4.17 – Percentuais da amostra masculina por faixa etária dos fatores de risco

MASCULINO		RISCOS											
Faixa de Idade		RMC				RCQ				RDC			
		0	1	2	3	4	1	2	3	1	2	3	4
< 20	8.3%						8.3%			8.3%			
20 – 29	8.3%	4.2%					12.5%			12.5%			
30 – 39	12.5%	16.7%	4.2%				25.0%	4.2%	4.2%	20.8%	8.3%	4.2%	
40 – 49		16.7%	12.5%				12.5%	16.7%		4.2%	20.8%	4.2%	
50 – 59		4.2%	4.2%					8.3%			4.2%	4.2%	
>= 60	4.2%	4.2%					4.2%	4.2%				8.3%	
	33.3%	45.8%	20.8%	0%	0%		62.5%	33.3%	4.2%	45.8%	33.3%	20.8%	0%

Tabela 4.18 – Percentuais da amostra masculina por faixa etária das avaliações de risco

4.4.3 – REPRESENTAÇÃO GRÁFICA DOS DADOS DA AMOSTRA

- *Diabetes Mellitus*

Situação	Feminino	Masculino	Total
Não sabe	25%	9%	34%
Não	47%	12%	59%
Sim	7%	1%	8%




Gráfico 4.5 – Indivíduos por sexo e classificação de diabetes

- *Tabagismo*

Situação	Feminino	Masculino	Total
Não Fumantes	66%	18%	84%
Fumantes	12%	4%	16%




Gráfico 4.6 – Indivíduos por sexo e classificação por tabagismo

- **HAS - Hipertensão arterial**

Situação	Feminino	Masculino	Total
1 - Não	54%	14%	68%
2 - Sim	25%	7%	32%




Gráfico 4.7 – Indivíduos por sexo e classificação por HAS

- **Risco Cintura/Quadril - RCQ**

Situação	Feminino	Masculino	Total
1 – Baixo	42%	13%	55%
2 – Moderado	27%	7%	34%
3 – Alto	11%	1%	12%

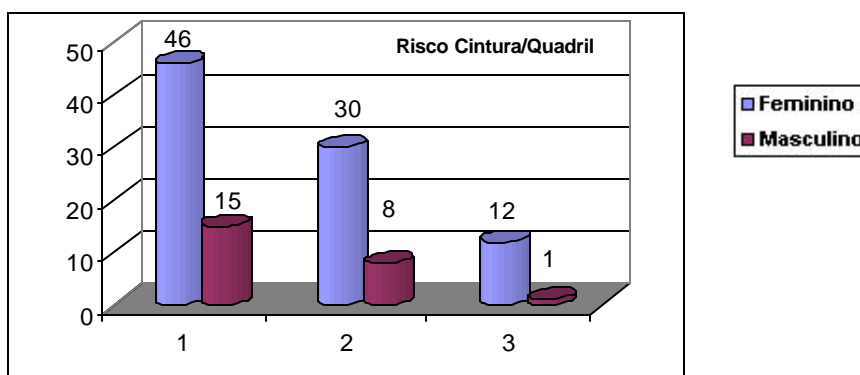


Gráfico 4.8 – Indivíduos por sexo e classificação por RCQ

- **Risco de massa corporal - RMC**

Situação	Feminino	Masculino	Total
1 – Baixo	35%	11%	46%
2 - Moderado	28%	9%	37%
3 - Alto	8%	2%	10%
4 – Muito Alto	7%	0%	7%




Gráfico 4.9 – Indivíduos por sexo e classificação por RMC

- **Risco de doenças coronarianas - RDC**

Situação	Feminino	Masculino	Total
1 – Baixo	40.7%	9.7%	50.4%
2 - Moderado	25.7%	7.1%	32.7%
3 - Alto	11.5%	4.4%	15.9%
4 – Muito Alto	0.9%	0%	0.9%




Gráfico 4.10 – Indivíduos por sexo e classificação por RDC

4.5 – ANÁLISE DO CONJUNTO DE DADOS DA AMOSTRA COM ALGORITMO DE RETROPROPAGAÇÃO NA REDE NEURAL

Em uma aplicação prática do algoritmo de retropropagação, o aprendizado resulta das muitas apresentações de um determinado conjunto de exemplos de treinamento para o perceptron de múltiplas camadas. Uma apresentação completa do conjunto de treinamento inteiro é denominada uma *época*. O processo de aprendizagem é mantido em uma base de época em época até os pesos sinápticos e os níveis de bias se estabilizarem e o erro médio sobre todo o conjunto de treinamento convergir para um valor mínimo.

4.5.1 – APRESENTANDO OS DADOS A REDE NEURAL

O conjunto de dados apresentado à rede para o processo de aprendizagem é composto de doze variáveis de entrada e uma de saída. O conjunto completo de dados da amostra encontra-se no anexo 2.

IDA	SEX	CT	HDL	LDL	TG	CT/HDL	IMC	ICQ	FU	DM	HAS	RDC
44	1	207	56	141	49	3.7	28.50	0.75	0	0	1	1
43	1	232	66	155	57	3.5	25.68	0.78	0	1	1	2
55	1	262	41	176	225	6.4	24.54	0.95	0	0	2	3
48	1	219	68	129	110	3.2	24.53	0.75	0	1	2	2
55	1	206	56	133	84	3.7	26.24	0.81	0	1	1	2
43	1	186	41	128	80	4.5	29.07	0.80	0	1	2	2
38	2	235	39	164	164	6.1	34.17	0.98	1	0	2	3
64	1	233	55	150	139	4.2	27.69	0.92	0	2	1	3
46	1	193	47	125	106	4.1	28.84	0.80	0	1	1	1
27	1	199	83	106	48	2.4	21.99	0.77	0	0	1	1
44	1	191	48	128	72	3.9	27.85	0.80	0	2	1	1
46	2	256	43	184	145	5.9	29.91	0.91	0	0	2	2
51	1	242	47	178	83	5.2	30.33	0.88	0	0	1	2
53	2	195	33	137	127	6.0	29.59	0.95	1	0	1	4
49	1	214	52	146	77	4.1	25.91	0.84	0	1	1	2

Tabela 4.19 - Conjunto de dados apresentados para treinamento da rede neural

Esses valores foram selecionados a partir do Microsoft Excel, copiados para a área de transferência do sistema operacional Windows (*clipboard*) e, através da função específica do software de rede neural, importado para sua tabela de conjunto de dados para treinamento, Fig. 4.4.

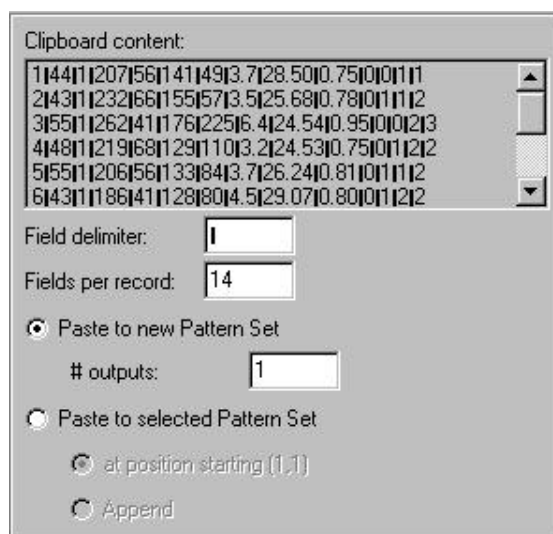


Figura 4.4 - Importação de dados da área de transferência

Rede 113.PAT											
	I6	I7	I8	I9	I10	I11	I12	O1	O1'	SQ	DV
1	49	3.70	28.50	0.75	0	0	1	1	--	--	
2	57	3.50	25.68	0.78	0	1	1	2	--	--	
3	225	6.40	24.54	0.95	0	0	2	3	--	--	
4	110	3.20	24.53	0.75	0	1	2	2	--	--	
5	84	3.70	26.24	0.81	0	1	1	2	--	--	
6	80	4.50	29.07	0.80	0	1	2	2	--	--	
7	164	6.10	34.17	0.98	1	0	2	3	--	--	
8	139	4.20	27.69	0.92	0	2	1	3	--	--	
9	106	4.10	28.84	0.80	0	1	1	1	--	--	
10	48	2.40	21.99	0.77	0	0	1	1	--	--	
11	72	3.90	27.85	0.80	0	2	1	1	--	--	
12	145	5.90	29.91	0.91	0	0	2	2	--	--	
13	83	5.20	30.33	0.88	0	0	1	2	--	--	
14	127	6.00	29.59	0.95	1	0	1	4	--	--	
15	77	4.10	25.91	0.84	0	1	1	2	--	--	
16	72	2.30	20.44	0.73	1	1	1	1	--	--	
17	89	2.60	19.72	0.71	0	0	1	1	--	--	
18	64	1.90	20.83	0.68	0	0	1	1	--	--	

Figura 4.5 – Tabela do conjunto de dados já importados

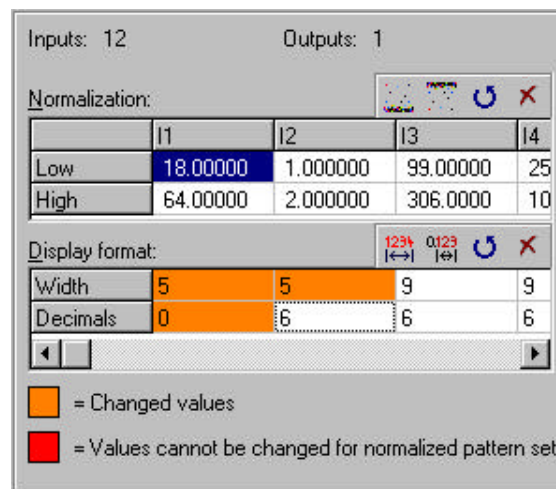


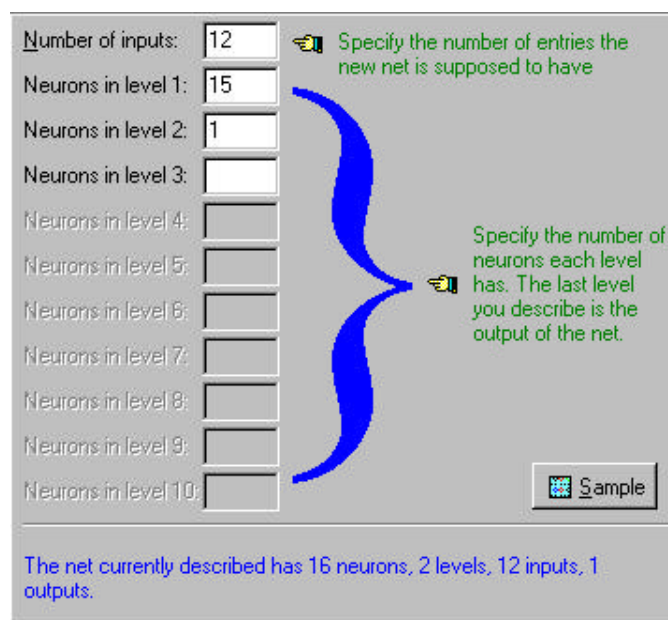
Figura 4.6 – Normalização do conjunto de dados

4.5.2 – CRIANDO MODELO DA REDE NEURAL

Uma rede neural é meramente uma forma pela qual o *conhecimento empírico* sobre um fenômeno físico ou o ambiente de interesse pode ser codificado através de treinamento. Por conhecimento “empírico” entendemos um conjunto de medidas que caracterizam o fenômeno.

Para determinar o grau de confiabilidade na informação de saída é necessário estabelecer o modelo ideal da rede neural, a quantidade de camadas intermediária, a quantidade de neurônios em cada camada intermediária. Hoje, pode-se contar com um grande número de softwares de rede neural, desde os mais simples desenvolvidos especificamente para resolver um único problema, até os mais completos que oferecem muito mais alternativas e são capazes de resolver problemas extremamente complexos. Dentre os mais populares encontram-se o MatLab, NeoNet, QuickNet e outros.

O software Pythia analisa o conjunto de dados de treinamento e apresenta uma topologia de rede neural, como ideal para o início de treinamento.



Number of inputs: Specify the number of entries the new net is supposed to have

Neurons in level 1:

Neurons in level 2:

Neurons in level 3:

Neurons in level 4:

Neurons in level 5:

Neurons in level 6:

Neurons in level 7:

Neurons in level 8:

Neurons in level 9:

Neurons in level 10:

Specify the number of neurons each level has. The last level you describe is the output of the net.

The net currently described has 16 neurons, 2 levels, 12 inputs, 1 outputs.

Figura 4.7 - Definindo a quantidade de neurônios da rede neural

Entretanto, pode-se alterar a quantidade de neurônios das camadas intermediárias (ocultas), de acordo com a quantidade de dados de entradas e quantas saídas desejadas para o aprendizado da rede, Fig. 4.7. A última camada de neurônios, será sempre o número de saídas (*Output*) desejado para o modelo.

Os neurônios de saída (nós computacionais) constituem a camada de saída da rede. Os neurônios restantes (nós computacionais) constituem as camadas ocultas da rede. Assim, a unidade oculta não é parte da saída ou da entrada da rede – daí a sua designação como “ocultas”. A primeira camada oculta é alimentada pela camada de entrada, constituída de unidades sensoriais (nós de fonte); as saídas resultantes da primeira camada oculta, por sua vez aplicadas à próxima camada oculta, e assim por diante para o resto da rede, (Haykin, 2001).

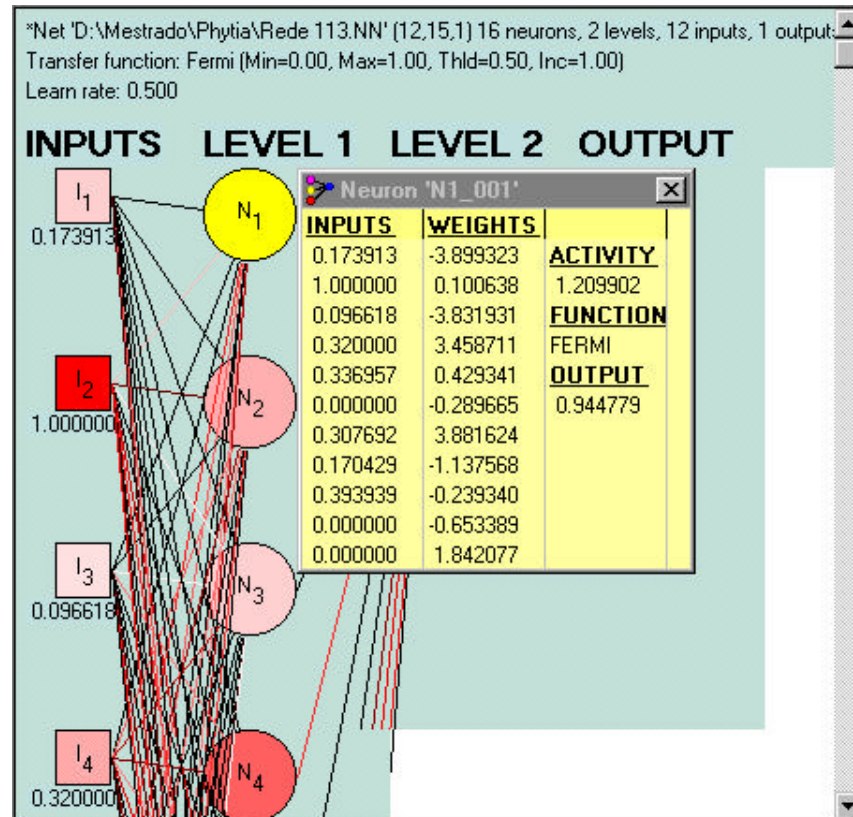


Figura 4.8 - Modelo da rede neural de retropropagação (*back-propagation*)

A figura 4.8 apresenta o modelo da rede neural determinado na fig. 4.7., com 16 neurônios em dois níveis, sendo 12 neurônios de entrada, 15 neurônios na camada intermediária (*oculta*) e 1 neurônio na camada de saída. Também são apresentados os valores de entrada e os pesos sinápticos do neurônio 1 da camada intermediária (*oculta*) da rede, antes de treinamento.

4.5.3 – O APRENDIZADO DA REDE NEURAL

A aprendizagem por retropropagação de um conjunto de treinamento pode ser realizada através de duas formas básicas:

1. *Modo Seqüencial*. O modo seqüencial de aprendizagem por retropropagação é também chamado de *modo on-line*, *modo padrão* ou *modo estocástico*. Neste modo de operação, a atualização dos pesos é realizada após a apresentação de cada exemplo de treinamento; este é o modo de

apresentação para o qual se aplica a derivação do algoritmo de retropropagação.

2. *Modo por lote.* No *modo por lote* da aprendizagem por retropropagação, o ajuste dos pesos é realizado *após* a apresentação de *todos* os exemplos de treinamento que constituem uma época, (Haykin, 2001).

O treinamento do conjunto de dados é determinado a partir da Fig. 4.9., abaixo:

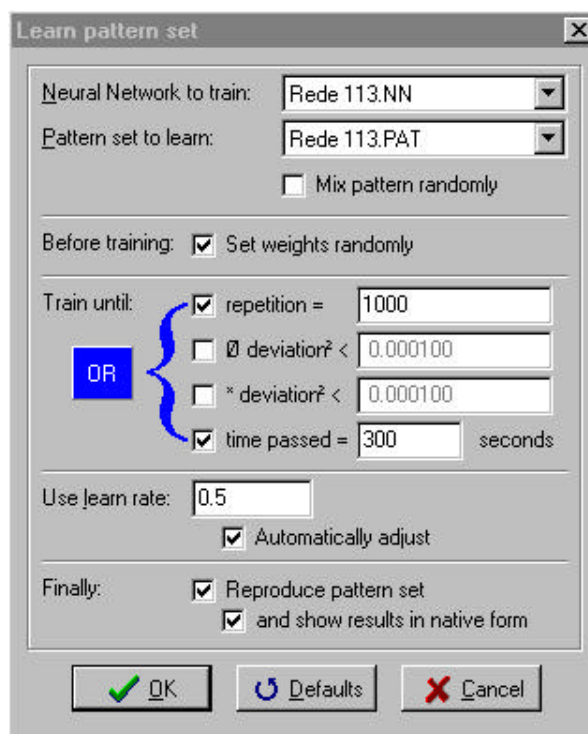


Figura 4.9 – Determinação do modo de treinamento para o conjunto de dados.

O software permite que, mais do que um conjunto de dados para treinamento esteja ativo ao mesmo tempo, bem como, definições diferentes de modelos da rede. Na Fig. 4.9., pode-se determinar qual o conjunto de dados e modelo da rede serão ativados para o treinamento, determinando ou não à utilização de pesos randômicos e a quantidade de vezes que o conjunto será apresentado para treinamento, (fig. 4.10).


```

Run: 732, Ø deviation²: 0.000210, max deviation²: 0.003462, Done: 73%
Run: 733, Ø deviation²: 0.000258, max deviation²: 0.005255, Done: 73%
Run: 734, Ø deviation²: 0.000186, max deviation²: 0.002556, Done: 73%
Run: 735, Ø deviation²: 0.000150, max deviation²: 0.001688, Done: 74%

```

Figura 4.10 – Execução do modo de treinamento para o conjunto de dados.

	I8	I9	I10	I11	I12	D1	D1(NE)	SQ	DV
1	28.50	0.75	0	0	1	1.00	1.03	0.000121	
2	25.68	0.78	0	1	1	2.00	1.98	0.000056	
3	24.54	0.95	0	0	2	3.00	2.99	0.000008	
4	24.53	0.75	0	1	2	2.00	1.96	0.000178	
5	26.24	0.81	0	1	1	2.00	1.96	0.000186	
6	29.07	0.80	0	1	2	2.00	2.03	0.000089	
7	34.17	0.98	1	0	2	3.00	2.99	0.000019	
8	27.69	0.92	0	2	1	3.00	3.00	0.000000	
9	28.84	0.80	0	1	1	1.00	1.03	0.000129	
10	21.99	0.77	0	0	1	1.00	1.00	0.000000	
11	27.85	0.80	0	2	1	1.00	1.00	0.000000	
12	29.91	0.91	0	0	2	2.00	2.03	0.000132	
13	30.33	0.88	0	0	1	2.00	1.82	0.003738	
14	29.59	0.95	1	0	1	4.00	3.98	0.000028	
15	25.91	0.84	0	1	1	2.00	1.98	0.000044	

Average deviation of 'Rede 113 best.NN': 0.000199

Figura 4.11 – Resultado do treinamento para o conjunto de dados.

Após a apresentação do conjunto de dados para o treinamento da rede, o resultado do valor de saída para cada um dos dados do conjunto é mostrado, juntamente, com o valor do desvio em relação ao valor de saída apresentado, (Fig. 4.11). Entretanto, o conjunto de dados de treinamento pode gerar um novo modelo de rede otimizado.

4.5.4 – OTIMIZAÇÃO EVOLUCIONÁRIA DO MODELO DA REDE NEURAL

O software empregado nesse trabalho faz uso de algoritmos evolucionários para a seleção e a geração de redes neurais otimizadas, submetendo parte de população do conjunto de dados (*padrão 50 registros*), continuamente ao treinamento e ajustando os novos modelos de redes neurais criados randomicamente a partir da seleção do conjunto de dados e o modelo inicial da rede desejado, Fig. 4.12.

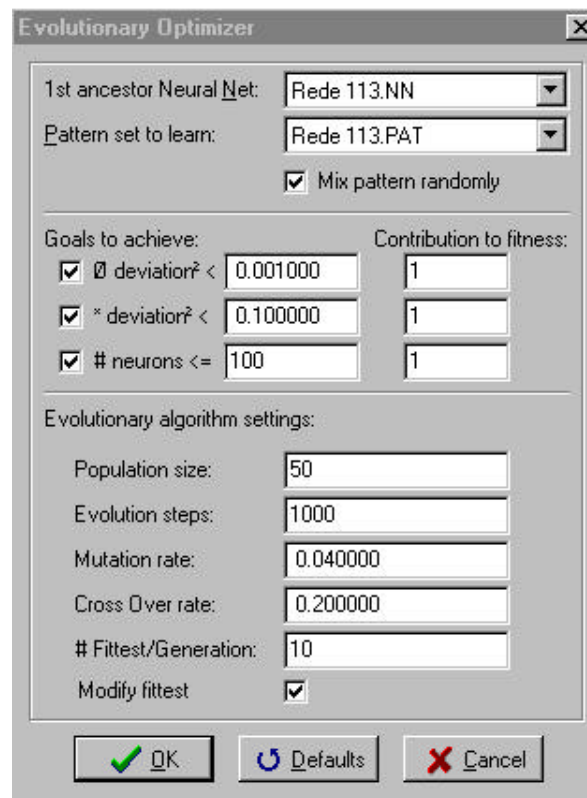


Figura 4.12 – Otimização evolucionária para o conjunto de dados

Evolutionary Optimization (Generation 10)					
Ancestor Net:		(12,15,1), 'D:\Mestrado\Phytia\Rede 113.NN'	Pattern Set:		
Goals:		(\emptyset deviation ² < 0.001000, 33.33%) AND (* deviation ² < 0.100000)			
GA settings:		1000 gen max, pop size 50, mutation rate 0.04, crossover rate 0.20,			
No	Topology	Neurons	\emptyset dev ²	* dev ²	Fitness
<input type="checkbox"/> 31	12,12,1	13	0.002582	0.049218	79.57712
<input type="checkbox"/> 32	12,12,1	13	0.001295	0.014191	92.40189
<input type="checkbox"/> 33	12,12,8,1	21	0.007516	0.102081	70.42246
<input type="checkbox"/> 34	12,12,1	13	0.003123	0.055707	77.34115
<input type="checkbox"/> 35	12,16,1	17	0.005571	0.089371	72.65035
<input type="checkbox"/> 36	12,12,1	13	0.001786	0.021556	85.32699
<input type="checkbox"/> 37	12,12,1	13	0.002233	0.033537	81.59256
<input type="checkbox"/> 38	12,14,1	15	0.003915	0.044344	75.17985
<input type="checkbox"/> 39	12,12,1	13	0.001211	0.015135	94.19534
<input type="checkbox"/> 40	12,12,1	13	0.001295	0.014191	92.40189
<input type="checkbox"/> 41	12,13,1	14	0.019156	0.174483	54.17749
<input type="checkbox"/> 42	12,12,12,1	25	0.008229	0.056158	70.71748
<input type="checkbox"/> 43	12,10,12,1	23	0.039586	0.344417	43.85356
<input type="checkbox"/> 44	12,12,1	13	0.001493	0.016957	88.99440
<input checked="" type="checkbox"/> 45	12,12,1	13	0.000967	0.011336	100.00000
<input type="checkbox"/> 46	12,12,1	13	0.003974	0.057973	75.05465
<input type="checkbox"/> 47	12,12,1	13	0.001892	0.023502	84.28197
<input type="checkbox"/> 48	12,16,1	17	0.007819	0.098939	70.92999
<input type="checkbox"/> 49	12,12,1	13	0.001125	0.011194	96.29359

Figura 4.13 – Geração da otimização evolucionária para o conjunto teste

A melhor topologia da rede neural obtida a partir do otimizador evolucionário Fig. 4.13, com o conjunto de dados padrão de teste, pode ser aplicado a qualquer conjunto dos dados para treinamento e teste.

4.5.5 – TESTANDO A REDE NEURAL COM UM ÚNICO CONJUNTO DE DADOS

A partir do conjunto único de dados (*12 variáveis de entrada*), Fig. 4.14., a rede já devidamente treinada, testa o conjunto individual dos dados, fornecendo o valor de saída para aquele conjunto, Fig. 4.15. Essa é uma maneira pela qual pode-se testar novos dados individualmente não pertencentes ao conjunto original de treinamento.

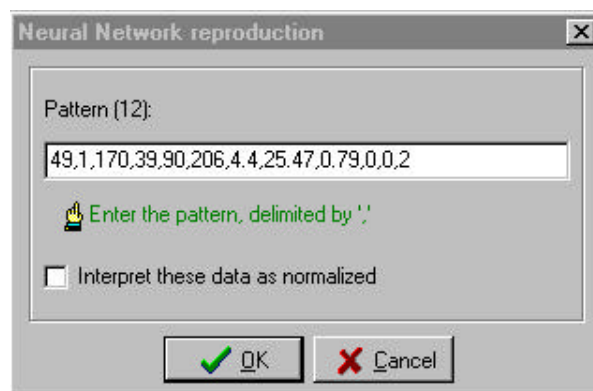


Figura 4.14 – Reprodução individual de dado para teste




Figura 4.15 – Resposta da reprodução individual de dado para teste

4.5.6 – CONJUNTO DE DADOS DE TREINAMENTO E TESTE

Este estudo utilizou os registros da amostra da tabela 4.18. O conjunto completo encontra-se no anexo 2. Do conjunto completo de dados foram reservados 80 registros para o treinamento inicial da rede, e 33 registros foram apresentados para teste. A topologia da rede foi composta de 12 neurônios na camada de entrada, 12 neurônios na camada intermediária e 1 neurônio na saída, com repetição de treinamento de 1000 vezes, e taxa de variação de 0.5. Os resultados foram os seguintes:

Conjunto de dados	Treinamento	Teste
Número de registros	80	33
Média de erro	0.53	0.18
Número de acertos exato	19	18
% de acertos exato	24%	55%
Número de acertos margem \pm 5%	68	33
% Acertos com margem \pm 5%	85%	100%
% Acertos com margem \pm 10%	99%	100%
Distorção	0.675	-0.176

Tabela 4.20 - Resultados do dados apresentados para treinamento e teste

4.5.7- RESULTADOS DOS ESTUDOS COM A REDE NEURAL

O estudo a seguir apresenta os resultados de ensaios sobre o conjunto de dados da amostra com a rede neural (*anexo 1*). O exemplo parcial dos dados na Tab. 4.19, contém as variáveis apresentadas no conjunto de dados para treinamento da rede, resultando no estudo da tabela 4.21.

RESULTADOS DOS ESTUDOS COM O CONJUNTO DE DADOS APLICADOS A REDE NEURAL											
		Estudo 1		Estudo 2		Estudo 3		Estudo 4		Estudo 5	
Topologia da Rede		12 15 1		12 12 1		12 12 1		12 12 1		6 7 1	
n.	RDC	RN-N	% DIF	RN-B	% DIF	RN-SZ	% DIF	RN-FS	% DIF	RN-L	% DIF
1	1	1.07	6.54	1.03	2.91	1.05	4.76	1.02	1.9€	1.29	22.48
2	2	2.07	3.38	1.98	-1.01	1.96	-2.04	1.97	-1.52	2.33	14.16
3	3	3.19	5.96	2.99	-0.33	2.99	-0.33	2.99	-0.33	3.54	15.25
4	2	1.77	-12.99	1.96	-2.04	2.01	0.50	1.95	-2.5€	2.18	8.26
5	2	2.05	2.44	1.96	-2.04	2.06	2.91	1.95	-2.5€	2	*
6	2	1.88	-6.38	2.03	1.48	2.02	0.99	1.97	-1.52	1.28	-56.25
...											
109	2	2.06	2.91	1.97	-1.52	2.04	1.96	1.97	-1.52	2.23	10.31
110	1	1	*	1	*	1	*	1	*	1.01	0.99
111	2	1.85	-8.11	1.89	-5.82	2	*	1.84	-8.6€	2.15	6.98
112	2	2.01	0.50	1.93	-3.63	2	*	1.91	-4.71	1.48	-35.14
113	1	1.06	5.66	1.02	1.96	1.03	2.91	1.02	1.9€	1.33	24.81
114	1	1	*	1	*	1	*	1.01	0.9€	1	*
VALORES RESULTANTES DO APRENDIZADO PELO CONJUNTO DE DADOS											
		Estudo 1		Estudo 2		Estudo 3		Estudo 4		Estudo 5	
Média de erro		-3.89		-0.06		1.51		-0.0€		-2.31	
Nro acertos exatos		26		50		36		41		29	
% Acertos exatos		23%		44%		32%		36%		26%	
Nro acertos ± 5%		82		97		87		111		70	
% acertos ± 5%		73%		86%		77%		98%		62%	
% acertos ± 10%		95%		100%		97%		99%		50%	
Distorçãc		-0.96		-0.103		-1.039		0.0€		-1.474	

Tabela 4.21 - Resultados dos estudos com os conjuntos de dados

Para todos os estudos, o conjunto de dados foi apresentado à rede para treinamento com repetição contínua de 1000 vezes, taxa de aprendizagem de 0.5, ajuste de pesos sinápticos randomicamente antes do treino.

Estudo 1 - Apresentados o conjunto de dados para treinamento, com a topologia da rede sugerida de 12 neurônios na camada de entrada, 15 neurônios intermediários (*ocultos*), e 1 neurônio de saída. Os resultados obtidos estão na Tab. 4.21.

Estudo 2 - A partir da topologia de rede do estudo 1, utilizando a função de otimização evolucionária do software, após 10 gerações de teste, (Fig. 4.13), um tempo de 18 minutos, apresentou a topologia com *fitness* de 100 (*considerada ótima pelo sistema*), com 12 neurônios na camada de entrada, 12 neurônios na camada intermediária (*ocultos*), e 1 neurônio de saída. Com essa topologia, a rede apresentou um acréscimo de 54% no número de acertos diretos passando de 26 para 50, diminui em 25% o número de erros, em relação ao estudo 1.

Além disso, apresentou uma diferença significativamente grande em relação à média de erro de -3.80 para -0.06 , o desvio médio de 8.59 para 2.40, e a distorção de valores de -0.96 para -0.091 .

Estudo 3 - A alteração no conjunto de dados apresentados para treinamento à rede neural, de forma a não apresentar valor zero para treinamento e teste. As variáveis LDL, FU e DM que apresentavam este valor, tiveram os valores de seus registros alterados de 0 para 0,1. A topologia permaneceu a mesma (12 12 1), do estudo 2. Entretanto, o resultado final ficou abaixo do obtido anteriormente. O número de acertos diminuiu 26%, o número de erros aumentou 17%, a média de erros passou de -0.06 para 1.51, o desvio médio de 2.40 para 3.50, e a distorção de valores de -0.091 para -1.39 .

Estudo 4 - Neste estudo, utilizamos o método descrito neste capítulo, no item 4.1.3.3., da substituição dos valores lipídicos (CT, HDL, LDL, TG) do conjunto de dados de treinamento, por valores resultantes da aplicação da *função logística sigmóide* (anexo 3). Os números passaram para um tamanho de 17 e precisão numérica de 16 casas decimais, permanecendo as demais variáveis inalteradas. A topologia da rede neural foi mantida a mesma do estudo 2 (12 12 1). Como resultado verifica-se que o número de acertos diminuiu em 20%, enquanto o número de erros aumentou 11%, em relação aos valores do estudo 2, sendo que a média de erros ficou próxima de -0.06 para -0.08 , o desvio médio foi superior ao do estudo 2, um valor de 2.27 comparados a 2.40 daquele estudo. Em relação aos estudos 1 e 3, este estudo mostrou resultados superiores.

Estudo 5 - Apenas 7 das 13 variáveis foram apresentadas como conjunto de dados para treinamento: *Idade, Sexo, CT, HDL, LDL, TG, RDC*, a mesma configuração do primeiro conjunto de teste. A melhor topologia da rede, através da função de otimização evolucionária, depois de 50 minutos de geração, foi 6 neurônios na camada de entrada, 7 neurônios na camada intermediária (*oculta*), e 1 neurônio na camada de saída. Este conjunto de dados de treinamento foi apresentado a rede, para analisar o seu comportamento em relação ao estudo 2, que contém todas as variáveis necessárias para avaliar o grau de *risco de doença coronária (RDC)*.

Comparativamente o número de acertos foi 42% menor, o número de erros cresceu 34%, apresentando a maior diferença no desvio médio de 2.40 para 24.98, comprovando que apenas com resultados laboratoriais, sem o histórico do paciente e as demais variáveis de acompanhamento, não se tem validação clínica.

4.5.8 – GRÁFICO DE REGRESSÃO LINEAR DO MELHOR ESTUDO

O melhor resultado apresentado pelo conjunto de dados, foi obtido no estudo 2. O gráfico 4.11 é apresenta a regressão linear entre o valor apresentado no conjunto de dados para treinamento como saída e o resultado apresentado pela rede neural após o treinamento. (eixo x = risco DAC avaliado pela forma clássica; eixo y = resultado treinamento da rede).




Gráfico 4.11 - Regressão linear do resultado do estudo 2

4.5.9 – COMPARAÇÃO DO RISCO RDC E RESULTADO OBTIDO PELA REDE

O gráfico 4.12 mostra um comparativo entre o resultado de avaliação clássica, fornecido como saída para a rede no conjunto de treinamento do estudo 2, com o resultado obtido pela rede após o treinamento.




Gráfico 4.12 – Gráfico comparativo do resultado do estudo 2

4.6 – Defuzzificação do risco de doença coronariana.

Fuzzy logic é a aplicação da Teoria dos Fuzzy Sets (FST) (*Conjuntos Difusos ou Nebulosos*) aos princípios da lógica clássica.

Tradicionalmente, a lógica é formulada matematicamente em termos de dualidade *falso / verdadeiro*, também conhecida como lógica *bivalente* ou *Aristotélica*. A aplicação da FST altera a fundamentação da lógica bivalente por considerar o conceito de *verdade parcial*. Isto porque, ser um membro de um conjunto difuso é uma questão de *grau* ou *gradação*. Portanto a *veracidade* ou *falsidade* de uma observação também o é. A teoria dos Fuzzy Sets e a Lógica Fuzzy tratam da *inexatidão*, que tem duas características básicas, *acurácia* e *precisão*. Acurácia e precisão têm significados diferentes e nem sempre são proximamente relacionados (Borges, 2000).

Precisão refere-se quase sempre à qualidade de uma medição.

Acurácia é a distância entre o valor médio e a verdade.

A utilização da lógica Fuzzy possibilitou uma definição maior do grau da avaliação de risco de doença coronariana, para um período de 10 anos, conforme mostra a tabela 4.20 com faixa de percentuais para o grau do risco. O estudo teve por base o mesmo conjunto de dados utilizados para o treinamento da rede (tabela 4.23)(Anexo 2).

TABELA DE RISCO CORONARIANO		
Muito Alto	5	Acima de 40%
Alto	4	20 a 40%
Moderado	3	10 a 20%
Leve	2	05 a 10%
Baixo	1	Abaixo de 5%

Tabela 4.22 - Grau de avaliação de DAC

IDA	SEX	CT	HDL	LDL	TG	CT/HDL	IMC	ICQ	FU	DM	HAS	RDC
44	1	207	56	141	49	3.7	28.50	0.75	0.1	1	1	1
43	1	232	66	155	57	3.5	25.68	0.78	0.1	1	1	2
55	1	262	41	176	225	6.4	24.54	0.95	0.1	1	2	3

Tabela 4.23 – Conjunto de dados de treinamento com RDC avaliado pelo método tradicional

A variável RDC, cujos valores de grau de risco estão entre 1 e 5, foi substituída por cinco variáveis. Os valores atribuídos às novas variáveis passaram a ser 0.1 ou 0.9, de acordo com o RDC. Para uma grau de risco 1 a variável S1, recebe o valor 0.9 e as demais 0.1 e assim sucessivamente, como mostra a tabela 4.24.

RDC	S1	S2	S3	S4	S5
1	0.9	0.1	0.1	0.1	0.1
2	0.1	0.9	0.1	0.1	0.1
3	0.1	0.1	0.9	0.1	0.1

Tabela 4.24 – Alteração do RDC para saída de acordo com o grau

O novo conjunto de dados para o treinamento da rede passou a ser o seguinte, tabela 4.24.

DA	SEX	CT	HDL	LDL	TG	CT/HDL	IMC	ICQ	FU	DM	HAS	S1	S2	S3	S4	S5
44	1	207	56	141	49	3.7	28.50	0.75	0.1	1	1	0.9	0.1	0.1	0.1	0.1
43	1	232	66	155	57	3.5	25.68	0.78	0.1	1	1	0.1	0.9	0.1	0.1	0.1
55	1	262	41	176	225	6.4	24.54	0.95	0.1	1	2	0.1	0.1	0.9	0.1	0.1

Tabela 4.25 – Conjunto de dados de treinamento com RDC modificado

A topologia da rede utilizada para o treinamento agora foi de 12 neurônios da camada de entrada, 12 neurônios na camada intermediária (*oculta*) e 5 neurônios na camada de saída, com exposição de repetição do conjunto de treinamento de 1000 vezes, e taxa de variação de 0.5., a tabela 4.26 abaixo apresenta um exemplo das saídas após o treinamento da rede.

S1	S2	S3	S4	S5	RN1	RN2	RN3	RN4	RN5
0.9	0.1	0.1	0.1	0.1	0.89990	0.10010	0.10000	0.10000	0.10000
0.1	0.9	0.1	0.1	0.1	0.10000	0.90000	0.10130	0.10000	0.10070
0.1	0.1	0.9	0.1	0.1	0.10000	0.10000	0.89940	0.10000	0.10000

Tabela 4.26 – Variáveis de RDC calculadas pela rede neural

Na determinação do valor de inferência, foram desconsiderados valores menores que **0.1**. São valores que foram atribuídos como saída normal para a rede e que não influenciaram no resultado. Os demais valores obtido pela rede neural foram multiplicado pelo maior percentual da faixa, tabela 4.20, com exceção dos valores do grau de risco 5, onde foi atribuído um valor de 70, de acordo com o crescimento proporcional dos valores das faixas anteriores, tabela 4.27.

RN1*5	RN2*10	RN3*20	RN4*40	RN5*70
4.4995	1.0010	*	*	*
*	9.0000	2.0260	*	7.0490
*	*	17.9880	*	*

Tabela 4.27 – Valores calculados pela rede multiplicados pelo grau do RDC

Na fórmula do cálculo do risco final também foram ignorados valores menores que 0.1.

$$RISCO = \frac{RN1 * 5 + RN2 * 10}{RN1 + RN2}$$

Surpreendentemente, os resultados obtidos através dessa nova abordagem foram compatíveis com resultados encontrados em outras pesquisas e publicações na área do estudo, porém, não de maneira tão direta ou com valores individualizados.

A tabela 4.25 (anexo 8), mostra um valor real do grau de avaliação de risco de doença coronariana, pela utilização da técnica dos conjuntos difusos, sobre o resultado do treinamento da rede neural.

RN1	RN2	RN3	RN4	RN5	RISCO	RDC
0.9	0.1	*	*	*	5.5%	1
*	0.9	0.101	*	0.101	16.4%	2
*	*	0.899	*	*	20.0%	3

Tabela 4.28 – Valores calculados pela rede e o percentual de RDC

4.6.1 – SOFTWARE DE LÓGICA FUZZY.

Como parte desse estudo foi utilizado o programa FUZZY Development and Generation Environment (FUDGE). A figura 4.16 mostra a pertinência do grau de risco de doenças coronarianas, dentro da lógica difusa, levando em consideração a forma clássica de avaliação.

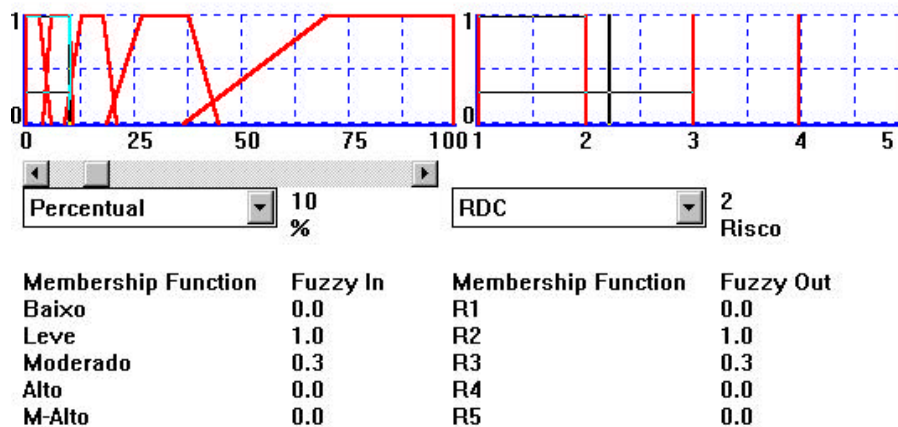


Figura 4.16 – Tabela de avaliação de pertinência do programa de lógica fuzzy




Figura 4.17 – Gráfico de pertinência do risco em relação ao percentual

4.6.2 – SCRIPT RESULTANTE DA UTILIZAÇÃO DO SOFTWARE FUDGE.

A seguir é apresentado o script utilizado no programa de lógica Fuzzy, contendo os valores e as regras de pertinência utilizados na avaliação do grau e do percentual de risco de doença coronariana, demonstrados nos Figuras 4.16 e 4.17.

INPUTS

Input #1

INPUT NAME	MIN	MAX	UNITS
Percentual	0	100	%

MEMBERSHIP FUNCTION

	P1	P2	P3	P4
Baixo	0	3	6	
Leve	4	10	11	
Moderado	9	18	21	
Alto	19	38	45	
M-Alto	37	70	100	

OUTPUTS

Output #0

OUTPUT NAME	MIN	MAX	UNITS
RDC	1	5	Risco

MEMBERSHIP FUNCTION

	P1
R1	1
R2	2
R3	3
R4	4
R5	5

RULES

Rule #1

IF Percentual IS Baixo
THEN RDC IS R1

Rule #2

IF Percentual IS Baixo
AND Percentual IS Leve
THEN RDC IS R2

Rule #3

IF Percentual IS Leve
THEN RDC IS R2

Rule #4

IF Percentual IS Leve
AND Percentual IS Moderado
THEN RDC IS R3

Rule #5

IF Percentual IS Moderado
THEN RDC IS R3

Rule #6
IF Percentual IS Moderado
AND Percentual IS Alto
THEN RDC IS R4

Rule #7
IF Percentual IS Alto
THEN RDC IS R4

Rule #8
IF Percentual IS Alto
AND Percentual IS M-Alto
THEN RDC IS R5

Rule #9
IF Percentual IS M-Alto
THEN RDC IS R5

CAPÍTULO 5

CONCLUSÃO

Este estudo demonstrou a potencialidade das redes neurais, também na área médica. O enfoque principal desse trabalho, foi associar variáveis de entrada relacionadas a dislipidemia, índice de massa corporal e índice cintura quadril, ao grau do fator de risco de doença coronariana, fornecido como valor de saída com resultados extremamente confiáveis.

Ficou comprovada a importância da associação do emprego da Lógica Difusa com as Redes neurais. O sistema de redes neurais quando integrada ao sistema de Lógica Fuzzy permite formar sistemas híbridos que podem muitas vezes capturar o melhor de ambas as tecnologias.

Na forma tradicional de avaliação, quando um paciente encontra-se numa classe de risco alto é impossível determinar a pertinência do mesmo em outras classes, ou seja, o indivíduo que se encontra no limite superior de uma classe normal, nunca saberá qual a sua probabilidade de passar para um grau mais alto de risco coronariano. Em outras palavras, na forma tradicional, o indivíduo que se encontra no limite inferior ou superior de uma classe é tratado da mesma forma. O sistema proposto e desenvolvido considera esse fato como uma questão muito relevante e chega a um novo índice que consegue medir esse fator. Os índices obtidos neste trabalho foram coerentes com a bibliografia existente, independente do tipo de diagrama de avaliação de risco coronariano utilizado. (SBC, 2001).

Como conclusões médicas é importante que se leve em conta todas as recomendações, consensos ou diretrizes, que têm como base dados epidemiológicos derivados de estudos realizados em outros países, abrangendo populações diferentes da brasileira, uma vez que não dispomos de dados suficientes nacionais. Assim, qualquer transposição que se faça desses dados para a nossa população corre-se o risco de não ser

completamente adequado. Além disso, salienta-se o fato de que o Brasil apresenta populações muito heterogêneas, com características regionais muito variáveis. Em relação a mortalidade por doença aterosclerótica no Brasil, sabe-se que o número de óbitos por 100.000 habitantes é de 46,9, apresentando ampla variação de acordo com a região estudada, com taxas maiores nas regiões Sul e Sudeste. (DATASUS, Ministério da Saúde).

Muitos estudos estão sendo realizados para, avaliar os fatores de riscos convencionais (ex., estudo caso-controle AFIRMAR – *Avaliação dos fatores de risco para infarto agudo do miocárdio no Brasil*) e fatores de riscos emergentes (ex., estudo caso-controle INTER-HEART – *A global case control study to identify the risk factors for acute myocardial infarction in different ethnic populations*) na população brasileira. Estes estudos ressaltam o impacto dos fatores de riscos mencionados sobre a população brasileira, podendo-se traçar estratégias preventivas eficientes por meio da iniciativa colaborativa, envolvendo sociedade, instituições e governos. A prevenção efetiva da doença cardiovascular requer estratégias amplas e globais, exigindo não só o conhecimento dos fatores de riscos convencionais e emergentes, mas também seu risco associado e impacto clínico sobre diferentes populações.

É importante salientar algumas evidências observadas na presente pesquisa:

1. Por ser um estudo voluntário entre funcionários do HU, notamos um número expressivo de indivíduos do sexo feminino, que não necessariamente reflete o perfil da UFSC, mas já demonstra a necessidade de valorização da prevenção de DAC em mulheres, 25,7% apresentam risco de DAC moderado, 12,4% já se encontram com alto risco de DAC, (Graf. 4.10). Isto se deve ao fato das mulheres apresentarem certas particularidades quanto ao aparecimento de DAC. Assim, sua eclosão é retardada em cerca de 7 a 10 anos, em relação ao sexo masculino (Lerner e Kannel, 1986), provavelmente em decorrência da cardioproteção conferida para estrogênio endógeno, durante a idade fértil. Além disso, as mulheres quando apresentam manifestação de DAC, tem pior prognóstico (Bertolami, 2001). Por outro lado, como as mulheres vivem mais do que os homens, e com o envelhecimento da população geral, admite-se que a prevalência da DAC terá expressivo aumento nas mulheres idosas.

2. Notamos também que 29,2% do grupo estudado, não apresenta níveis de colesterol dentro do ideal, (tab. 4.11) esse grupo em especial necessitaria atenção direcionada a prevenção de DAC.
3. Quanto a obesidade, que geralmente está associada a outros fatores de riscos cardiovasculares, como HAS, Diabetes e Dislipidemia, notamos que menos da metade (45,1%) dos indivíduos estudados estão fora dos níveis normais. (tab. 4.12) Seus determinantes incluem fatores genéticos, sócio-econômicos e comportamentais. A melhora do nível sócio-econômico de uma população é acompanhada por aumento de suas taxas de peso, altura e obesidade abdominal. Isto revela a necessidade de mudanças comportamentais, decisivas e rápidas como medida principal para diminuir o impacto epidemiológico da obesidade na população.
4. O consumo de cigarro varia amplamente de acordo com o sexo e as regiões geográficas. Felizmente no nosso meio notamos que 84.1% não faz uso do tabagismo.(Tab. 4.11 e Graf. 4.6). Isso é importante porque fortes evidências demonstram a relação causal entre o tabaco e o desenvolvimento de DAC. Cerca de 6% das mortes no ano de 1990 foram decorrentes do consumo de cigarro, e devemos com atividades educacionais tentar diminuir esta incidência.
5. Mesmo conhecendo-se que o diabetes é um fator de risco independente para DAC, existem evidências de que níveis glicêmicos moderadamente aumentados também aumentariam o risco para DAC. Em nosso estudo, notamos que mesmo sendo funcionários de um hospital escola, profissionais da saúde, 34% destas pessoas não tinham conhecimento de seus níveis glicêmicos (Tab. 4.11), apesar de realizarem exames periódicos conforme a lei. Isto prova que existe um hiato imenso entre os conhecimentos médicos e sua aplicação.
6. Em nosso grupo a hipertensão arterial se mostrou um fator de risco significativo e independente para DAC. A taxa de incidência de conhecimento de HAS ficou em torno de 32%, mas infelizmente nos deparamos com 26,5% dos funcionários pesquisados apresentando níveis não desejáveis de pressão arterial.

Estas evidências acima vêm corroborar a idéia vigente de que a prevenção é a maneira mais barata de diminuir a incidência de DAC, mas que a prevenção exige um esforço continuado e intensivo para mudar hábitos culturais nocivos enraigados em nossa população. Entretanto, temos certeza que esse esforço tem resultados positivos e duradouros.

5.1 – SUGESTÕES PARA OUTROS TRABALHOS.

Esta foi a primeira etapa de um estudo que se propõe a ser longitudinal, e serviu como base para validação da continuidade do uso de redes neurais, e como proposta para outros trabalhos, seria importante:

- O desenvolvimento de um software integrado de avaliação do risco coronariano e análise de redes neurais diretamente do banco de dados, permitindo o acompanhamento da evolução dos dados em etapas posteriores.
- A substituição do método utilizado de pesquisa em banco de dados com 800 variáveis combinatórias de resultados, pelo uso de *algoritmos genéticos* ou *Rough Sets*, devido à explosão combinatória de resultados possíveis, sem a discretização dos valores.
- Continuar o estudo da utilização de Redes Neurais e Lógica Fuzzy, acrescentando novas variáveis como avaliação de stress, atividade física e fatores de riscos emergentes..

REFERÊNCIAS BIBLIOGRÁFICAS

1. ACKLEY, D.H.; HINTON, G.E.; SEJNOWSKI, T.J., **A learning algorithm for Boltzmann machines**, Cognitive Science, vol.9, 1985, pp.17-169.
2. ANDERSON, J.A., **General introduction**, Neurocomputing: Foundations of Research (J.A. Anderson and E. Rosenfeld, eds), pp.xiii-xxi, Cambridge, MA : MIT Press, 1988.
3. ANDERSON, J.A., **Introduction to neural networks**, Cambridge, MA : MIT Press, 1995.
4. ARBIB, M.A., **Brains, machines, and mathematics**, 2nd edition, New York :Springer-Verlag, 1987.
5. ARBIB, M.A., **The metaphorical brain**, 2nd edition, New York : Wiley, 1989.
6. ASSMANN G; et al; **The emergence of triglycerides as a significant independent risk factor in coronary artery disease**. European Heart Journal 1998; 19(M):M8-M14.
7. BARRETO, J.M.; **Inteligência artificial : No Limiar do Século XXI**, Florianópolis : PPP Edições, 1997.
8. BARTO, A.G. et.al.; **Neuronlike adaptive elements than can solve difficult learning control problems**, IEEE Transactions on Systems, Man, and Cybernetics, vol. SMC-13, 1983, pp.834-846.
9. BECKER, S.; **Unsupervised learning procedures for neural networks**, International Journal of Neural Systems, vol.2, 1991, pp.17-33.
10. BERTOLAMI, M.C.; **Avaliação do risco lipídico pela relação LDL/HDL colesterol**; Instituto Dante Pazzanese de Cardiologia da Secretaria da Saúde do Estado de São Paulo. 2001. 3-10.
11. BERTOLAMI, M.C.; et.al. **Dislipidemias no sexo feminino** : Revista Brasileira de Medicina : São Paulo, Vol. 58; Ed. Especial 12/2001, pg. 173-183.
12. BORGES, P.S.S.; **Introdução à Inteligência Computacional**, UFSC, Apostila do curso ciência da computação : 2000.
13. BROWN, T.H., et al., **Hebbian synapses: biophysical mechanisms and algorithms**, Annual Review of Neuroscience, vol.13, 1990, pp.475-511
14. CARVALHO FILHO, E.C.B., **Modelagem, Aplicações e Implementações de redes Neurais**. Anais da IV Escola Regional de Informática da SBC Regional Sul, 21 a 27 de abril de 1996. p. 36-53.
15. CHAVES Jr, H; **Hipertensão Arterial: Aspectos epidemiológicos e grupos especiais de risco**. Revista ILIB, ano 3, 1, 2001. 5-11.
16. COMBS, G.F. **The vitamins fundamental aspects in nutrition and health**. 2 ed. Academic Press, New York:, p. 246-275, 1998.
17. DEMUTH, H; BEALE, M. **Neural Network Toolbox** : Natick USA : The

Mathworks inc : 2001

18. EBERHARDT, R; SIMPSON, P; DOBBINS, R.; **Computacional intelligence PC Tools**. Orlando FL, Academic Press, Inc. 1996.
19. EGGERMONT, J.J., **The correlative brain: theory and experiment in neural interactions**, New York : Springer-Verlag, 1990.
20. FAUCI, at al. : **Cardiopatia Isquêmica**, in Harrison: Medicina Interna, 14a ed, vol I. McGraw Hill, 1998.
21. FISCHLER, M.A; O. Firschein., **Intelligence: the eye, the brain, and the computer**, Addison-Wesley : Reading, MA., 1987
22. FRIDEWALD W.T., LEVI R.L.; FREDRICKSON D.S. **Estimation of the concentration of low-density lipoprotein cholesterol in plasma without use of the preparative ultracentrifuge**. Clin Chem 1972; 18: 499-502
23. GALE, C.R. at al., **Vitamin C and risk of death from stroke and coronary heart disease in cohort of elderly people**. Br Med J., v. 310, p. 1563-1569, 1995.
24. GORNI, A.A, **Redes Neurais Artificiais - Uma Abordagem revolucionária em Inteligência Artificial**. Revista Micro Sistemas : ed.133 p. 14-25 : ed. 134 p. 14-17, Ano XII.
25. GRIFFITHS, L.J.; JIM, C.W., **An alternative approach to linearly constrained optimum beamforming**, IEEE Transactions on Antennas and Propagations, vol. AP-30, 1982, pp.27-34.
26. GUPTA, M.M; RAO, D.H.; **Neuro-Control Systems**. Um volume selecionado reeditado. IEEE Neural Networks Council, Sponsor.
27. HAYKIN, S.; **Adaptive filter theory**, 3rd edition, Englewood Cliffs, NJ : Prentice-Hall, 1996.
28. HAYKIN, S.; **Redes Neurais principio e prática**; 2 ed : Porto Alegre : Bookman : 2001, pp.1-181.
29. HEBB, D.O.; **The organization of behavior: A neuropsychological Theory**, Wiley : New York, 1949.
30. HECHT-NIELSEN, R.; **Neurocomputing**. HNC, Inc. and University of California, San Diego.
31. HINTON, G.E., **Connectionist learning procedures**, Artificial Intelligence, vol. 40, 1989, pp.185-234.
32. HINTON, G.E.; SEJNOWSKI, T.J., **Learning and relearning in Boltzmann machines, in Parallen Distributed Processing: Explorations in Microstructure of Cognition**, D.E. Rumellhat and J.L. McClelland, eds., Cambridge, MA : MIT Press, 1986.
33. INTROCASO, L.; **História natural da aterosclerose**; São Paulo : Ateros, vol 12 1 2001.

34. JENNER, J.L., et al., **Ascorbic acid supplementation does not lower plasma lipoprotein(a) concentrations**. *Atherosclerosis*, v. 51, p. 541-544, 2000.
35. KOVÁCS, Z.L. - **Redes Neurais Artificias**. 2 ed. : Collegium Cognitio : 1996
36. LAURES-VALE, AA; MARTINEZ, T.L.R.; **Prevenção: importância e estratificação de risco** : *Atheros*, São Paulo, Vol. 12 1 2001, pg. 7-12.
37. LERNER DJ, KANNEL WB. **Patterns of coronary heart disease morbidity and mortality in the sexes: a 26-year follow-up of the Framingham population**. *Am Heart Journal* 1986: 111:383-90
38. LINSKER, R., **Self-organization in a perceptual network**, *Computer*, vol.21, pp.105-117, 1988.
39. LOTUFO, P.A.; **Epidemiologia das doenças cardiovasculares: Impacto do aumento da obesidade na população Brasileira** : *Revista ILIB*, ano 3, 3, 2001. 5-15.
40. MACRUZ R; **Dor cardíaca** : São Paulo : Sarvier, 1976, 1.
41. MATSUMOTO, É.Y.; **Matlab 6 fundamentos de programação** : São Paulo : Érica, 2001, 2.ed.
42. McCULLOCH, W.S.; PITSS, W. **A logical calculus of the ideas immanent in nervous activity** : *Bulletin of Mathematical Biophysics*, 1990, vol. 5, p.115-133
43. MICHELON, E.; MORIGUCHI, E.H.; **Dislipidemia em idosos: devemos tratar?** São Paulo : *Dislipidemia Today* : 01 04/2000; 3-11.
44. MILLER, O.; GONÇALVES, R.R.; **Laboratório para o clínico**. 8.ed. São Paulo: Atheneu, 1999. p. 17-26 : 434-439
45. MINSKY, M.L.; PAPER, S.A., **Perceptrons** , Cambridge, MA : MIT Press, 1969.
46. NILSSON, N.J., **Principles of artificial intelligence**, Springer-Verlag, 1980.
47. PEARL, J., **Probabilist reasoning in intelligent Systems**, San Mateo, CA: Morgan Kaufmann. (Revised 2nd printing, 1991) : 1988.
48. PRICE, K.D., et al., **Hyperglycemia-induced ascorbic acid deficiency promotes endothelial dysfunction and the development of atherosclerosis**. *Atherosclerosis* v. 158, p.1-12, 2001.
49. QUEIROZ JR, OG; **Aterosclerose**; Disponível em:
<http://www.zemoleza.com.br/trabalho.asp?cod=1455> : Acessado em: 22/03/2002
50. RALL, W., **Some historical notes** : in *Computational Neuroscience* : E.L. Schwartz, Cambridge: MIT Press, 1990, pp.3-8.
51. RAMÓN y Cajál, S., **Histologie du Systéms Nervoux de l'homme et des vertébrés** : Maloine : Paris, 1911.
52. RASMUS, D.W. **Pensando sobre a inteligência artificial: Cyberlife!**. São Paulo : Berkley, 1995.

53. RONSEIN G.; et al; **Influência do estresse nos níveis sanguíneos de lipídios, de ácido ascórbico, de zinco e de outros parâmetros bioquímicos** : NIPEAD : UFSC, 2001.
54. ROSENBLATT, F., **Principles of neurodynamics**, Washington, DC : Spartan Books, 1962.
55. ROSENBLATT, F., **The perceptron: a probabilistic model for information storage and organization in the brain**, Psychological Review, vol. 65, 1958, pp.386-408.
56. RUMELHART, D.E.; McCLELLAND, J.L., **Parallel distributed processing** : Explorations in the Microstructure of Cognitions, vol.1, Cambridge, MA : MIT Press, 1986.
57. RUMELHART, D.E.; ZIPSER, D., **Feature discovery by competitive learning**, Cognitive Science, vol.9, 1985, pp.75-112.
58. RUNTIME SOFTWARE; Pythia – **The Neural Network Designer User's Guide** : 2000
59. RUSSEL, S.J., NORVIG, P., **Artificial intelligence: A modern approach**, Upper Saddle River, NJ : Prentice-Hall, 1995.
60. RUSSO, A.P., **Neural Network for sonar signal processing**, Tutorial No.8, IEEE Conference of Neural Networks for Ocean Engineering, Washington, DC.
61. SAGE, A.P., **Concise Encyclopedia of information processing in Systems and Organizations**, Pergamon : New York, 1990.
62. SBC-SOCIEDADE BRASILEIRA DE CARDIOLOGIA: **Arquivos Brasileiros de Cardiologia, Resumo das III Diretrizes Brasileiras sobre Dislipidemias e Diretriz de Prevenção da Aterosclerose**, São Paulo, Vol. 77, Suplemento III, 11/2001.
63. SBC-SOCIEDADE BRASILEIRA DE CARDIOLOGIA: **Consenso Brasileiro sobre Dislipidemias: detecção, avaliação e tratamento. Arquivos Brasileiros de Cardiologia**, São Paulo, 1993; 61 (supl I):I1-II3
64. SBC-SOCIEDADE BRASILEIRA DE CARDIOLOGIA; **Dicionário Médico**; Disponível em: <http://www.cardiol.br/sbc-funcor/cuide/dicionario/b.asp?codses=2>, Acessado em: 08/04/2002
65. SILVA, E.L.; et.al., **Avaliação da interferência do ácido ascórbico nas reações para a detecção de glicose e hemoglobina urinárias**. Rev. Bras. Anal. Clínicas, v. 32, n. 1, p.15-20, 2000.
66. SIMON, J.A.; HUDES, E. **Serum ascorbic acid and cardiovascular disease prevalence in u.s. adults: the third national health and nutrition examination survey**, (NHANES III). Ann. Epidemiol. v. 9 , p. 358-365, 1999.
67. STEVENSON, W.J; **Estatística Aplicada a Administração** : São Paulo : Harba, 1981.

68. STONE, N.J; BLUM C.B; WINSLOW, E.; **Manejo dos Lipídio na prática clínica.**: 2.ed. Rio de Janeiro : Novartis, s/d.
69. SUGA, N., **Computations of velocity and range in the bat auditory systems for echo location** : in *Computational Neuroscience* : E.L.Schwartz, ed. Cambridge: MIT Press, 1990b, pp.213-231.
70. SUGA, N., **Cortical computational maps for auditory imaging** : *Neural Networks*, 1990a, vol.3, pp.3-21.
71. SZKLO, M.; NIETO, F.J.; **Infecção e doença cardiovascular – Arteriosclerose** : *Revista Ciência Hoje* : Outubro de 1999, vol. 26 : nr. 154 : p25.
72. TEYLER, T.J., **Memory: electrophysiological analogs**, in *Learning and Memory: A Biological View*, J.L.Martinez, Jr. and R.S. Kesner,eds., pp.237-265, New York : Academic Press, 1986.
73. The Math Works Inc; **MATLAB for Windows User’s Guide** , 2001.
74. VALKONEN, M., KUUSI, T., **Vitamin C Prevents the Acute Atherogenic Effects of Passive Smoking**. *Free Radical Biol. Med.*, v. 28, n. 3, p. 428-436.
75. VAN VEEN, B., **Minimum variance beamforming**, in S.Haykin and A.Steinhardt, eds., *Adaptive Radar Detection and Estimation*, New York : Wiley (Interciencia), 1992.
76. WALTRICK, C.D.A. et al; **Perfil lipídico, índice de massa corporal e antropométrico – índice relação cintural quadril, dos funcionários do Hospital Universitário da Universidade Federal de Santa Catarina – estudo longitudinal etapa I** : NIPEAD/HU/UFSC : 2001.
77. WIDROW, B.; HOFF Jr, M.E., **Adaptive switching circuits**, IRE WESCON Convention Record, 1960, pp.96-104
78. WIDROW, B.; STEAMS, S.D., **Adaptive signal processing**, Englewood Cliffs, NJ : Prentice-Hall, 1985.

Anexo 1 – Tabela do conjunto de dados da amostra populacional

n.	IDA	SEX	CT	HDL	LDL	TG	CT/HDL	IMC	ICQ	FU	DM	HAS	RCQ	RIMC	RDC
1	44	1	207	56	141	49	3.7	28.50	0.75	0	0	1	1	1	1
2	43	1	232	66	155	57	3.5	25.68	0.78	0	1	1	1	1	2
3	55	1	262	41	176	225	6.4	24.54	0.95	0	0	2	3	0	3
4	48	1	219	68	129	110	3.2	24.53	0.75	0	1	2	1	0	2
5	55	1	206	56	133	84	3.7	26.24	0.81	0	1	1	2	1	2
6	43	1	186	41	128	80	4.5	29.07	0.80	0	1	2	2	1	2
7	38	2	235	39	164	164	6.1	34.17	0.98	1	0	2	3	2	3
8	64	1	233	55	150	139	4.2	27.69	0.92	0	2	1	3	1	3
9	46	1	193	47	125	106	4.1	28.84	0.80	0	1	1	2	1	1
10	27	1	199	83	106	48	2.4	21.99	0.77	0	0	1	1	0	1
11	44	1	191	48	128	72	3.9	27.85	0.80	0	2	1	2	1	1
12	46	2	256	43	184	145	5.9	29.91	0.91	0	0	2	2	1	2
13	51	1	242	47	178	83	5.2	30.33	0.88	0	0	1	3	2	2
14	53	2	195	33	137	127	6.0	29.59	0.95	1	0	1	2	1	3
15	49	1	214	52	146	77	4.1	25.91	0.84	0	1	1	2	1	2
16	24	1	187	80	92	72	2.3	20.44	0.73	1	1	1	1	0	1
17	20	1	188	72	98	89	2.6	19.72	0.71	0	0	1	1	0	1
18	23	1	164	87	65	64	1.9	20.83	0.68	0	0	1	1	0	1
19	28	1	168	71	88	44	2.4	22.15	0.84	0	1	2	1	0	1
20	42	1	126	50	0	44	2.5	21.99	0.75	0	1	1	1	0	1
21	23	1	163	65	0	44	2.5	20.70	0.66	0	0	1	1	0	1
22	44	1	190	38	139	67	5.0	21.50	0.83	1	0	1	2	0	1
23	41	1	283	56	162	324	5.1	36.95	0.84	0	0	2	2	3	3
24	31	1	99	72	0	44	0.0	28.51	0.71	1	0	1	1	1	1
25	38	1	163	68	86	47	2.4	32.89	0.91	0	0	2	3	2	1
26	18	2	99	44	0	54	0.0	20.30	0.81	0	1	1	1	0	1
27	45	1	159	36	90	165	4.4	37.66	0.94	0	1	2	3	3	2
28	52	2	178	53	109	79	3.3	30.47	0.91	0	0	1	2	2	2
29	44	1	189	68	110	54	2.8	20.57	0.73	0	0	2	1	0	2
30	30	1	132	49	75	44	2.7	20.20	0.74	1	0	1	1	0	1
31	46	1	175	61	98	81	2.9	18.99	0.77	0	1	1	1	0	1
32	43	1	150	40	90	102	3.8	22.94	0.83	1	0	1	2	0	2
33	50	1	189	92	91	44	2.1	21.11	0.88	0	1	1	3	0	1
34	36	2	104	25	37	212	4.2	23.15	0.91	1	0	1	2	0	2
35	27	2	113	37	66	44	3.0	22.77	0.76	0	1	1	1	0	1
36	51	1	167	48	90	148	3.5	29.96	0.81	1	1	1	2	1	1
37	33	1	188	47	124	81	4.0	29.37	0.76	0	1	1	1	1	1
38	33	2	139	42	82	79	3.3	23.81	0.86	0	0	1	1	0	1
39	41	1	160	60	80	99	2.7	26.31	0.72	0	1	2	1	1	1
40	40	1	157	46	94	89	3.4	21.81	0.75	1	1	1	1	0	2
41	48	2	189	44	115	147	4.3	27.21	0.94	0	1	2	2	1	2
42	21	1	131	35	79	90	3.8	27.17	0.83	0	1	1	2	1	1
43	45	1	228	70	140	91	3.3	21.01	0.65	0	1	1	1	0	2
44	53	1	134	46	66	108	2.9	35.38	0.84	0	2	2	2	3	3
45	49	2	187	33	122	158	5.6	24.32	0.89	0	1	1	1	0	2
46	41	1	172	31	113	143	5.6	23.50	0.78	0	0	1	1	0	1
47	36	2	194	43	118	164	4.5	25.86	0.87	0	1	1	1	1	1
48	48	2	218	43	155	96	5.1	22.82	0.88	0	1	1	1	0	2
49	48	1	164	45	94	126	3.7	20.62	0.77	0	1	1	1	0	2
50	42	1	171	56	93	113	3.1	29.27	0.79	0	1	2	1	1	2
51	49	1	219	67	117	175	3.3	26.25	0.78	0	1	2	1	1	2
52	31	1	180	57	100	115	3.1	19.78	0.78	0	1	1	1	0	1
53	36	1	160	62	88	52	2.6	22.19	0.76	0	1	1	1	0	1
54	43	1	193	45	125	114	4.3	29.15	0.79	0	2	1	1	1	1
55	40	1	225	100	0	53	0.0	22.81	0.70	0	1	1	1	0	2
56	37	1	133	43	79	54	3.1	27.34	0.85	1	1	1	2	1	1
57	48	1	192	47	131	66	4.1	38.95	0.78	0	1	1	1	3	1
58	39	1	202	71	0	44	2.8	22.48	0.69	0	1	1	1	0	1
59	37	1	207	60	136	57	3.5	21.48	0.74	0	1	1	1	0	1
60	49	1	223	63	116	220	3.6	33.12	0.89	0	2	2	3	2	3
61	43	1	181	48	121	60	3.8	24.50	0.82	1	1	1	2	0	2
62	47	2	178	26	128	122	6.9	23.88	0.95	1	0	2	2	0	3
63	39	2	220	41	134	222	5.4	24.01	0.87	0	1	2	1	0	2
64	45	1	192	63	107	111	3.1	25.43	0.77	0	1	1	1	1	1
66	34	1	178	82	82	69	2.2	22.22	0.78	0	0	1	1	0	1
67	33	2	172	35	113	123	5.0	25.00	0.84	0	0	1	1	1	1
68	20	1	133	46	76	51	2.9	28.77	0.83	0	1	1	2	1	1
69	40	1	185	53	112	99	3.5	22.94	0.85	1	0	1	2	0	2

n.	IDA	SEX	CT	HDL	LDL	TG	CT/HDL	IMC	ICQ	FU	DM	HAS	RCQ	RIMC	RDC
70	50	1	256	66	180	48	3.9	20.62	0.74	0	1	1	1	0	3
71	46	1	262	34	177	257	7.7	29.90	0.79	0	0	2	1	1	3
72	60	2	161	46	106	49	3.5	20.45	0.80	0	1	2	1	0	3
73	47	1	167	63	94	51	2.6	20.23	0.84	0	1	1	2	0	1
74	41	1	212	39	142	156	5.4	30.78	0.80	0	0	1	2	2	2
75	42	1	179	56	113	52	3.2	20.78	0.80	1	1	1	2	0	2
76	47	1	191	56	99	182	3.4	31.53	0.82	0	2	2	2	2	2
77	48	1	223	34	154	179	6.6	36.39	0.83	1	1	2	2	3	3
78	35	1	189	52	113	124	3.6	20.37	0.80	0	1	1	2	0	1
79	28	1	157	68	81	44	2.3	20.66	0.72	0	1	1	1	0	1
80	39	1	247	42	181	116	5.8	25.25	0.84	0	0	1	2	1	1
81	52	1	207	43	150	75	4.9	37.92	0.85	0	0	2	2	3	3
82	42	1	183	47	119	86	3.9	32.67	0.74	0	1	1	1	2	1
83	36	1	223	53	158	55	4.2	26.29	0.82	0	1	1	2	1	1
84	50	1	227	100	0	62	0.0	20.45	0.77	1	2	2	1	0	3
85	41	1	218	60	122	184	3.6	33.15	0.75	0	0	1	1	2	2
86	48	1	181	33	131	86	5.5	29.00	0.94	0	1	2	3	1	2
87	47	1	188	69	100	94	2.7	28.76	0.85	0	1	1	1	1	1
88	42	1	189	43	117	144	4.4	22.95	0.83	0	1	1	2	0	1
89	45	1	219	44	157	88	5.0	29.76	0.90	0	1	2	3	1	2
90	18	2	145	34	98	62	4.2	21.05	0.75	0	1	2	1	0	1
91	42	1	178	34	134	49	5.3	27.78	0.79	1	0	2	1	1	2
92	51	1	306	39	133	166	7.8	35.44	0.84	0	2	2	2	3	4
93	48	1	172	48	109	74	3.6	34.24	0.86	0	1	2	3	2	3
94	48	1	194	49	130	75	4.0	35.70	0.91	0	1	2	3	3	3
95	64	2	186	38	124	121	4.9	25.91	0.90	0	2	2	2	1	3
96	28	1	167	60	96	58	2.8	31.64	0.80	0	0	1	2	2	1
97	28	1	99	42	0	44	0.0	22.38	0.73	0	0	1	1	0	1
98	26	2	184	35	125	116	5.2	28.70	0.87	0	1	1	1	1	1
99	41	1	187	60	118	44	3.1	22.23	0.71	0	1	1	1	0	1
100	46	2	207	51	134	113	4.1	26.17	0.91	0	1	1	2	1	2
101	52	1	183	50	119	73	3.7	28.76	0.92	0	1	2	3	1	3
102	54	1	170	60	94	79	2.8	19.56	0.78	0	1	2	1	0	3
103	50	1	133	51	66	78	2.6	16.36	0.77	0	1	1	1	0	2
104	21	1	214	72	130	58	3.0	26.84	0.75	0	1	1	1	1	1
105	42	1	174	61	106	44	2.8	28.67	0.79	0	0	1	1	1	1
106	37	2	177	49	109	98	3.7	26.28	0.82	0	0	1	1	1	1
107	42	1	188	71	101	80	2.6	22.60	0.85	0	1	1	2	0	1
108	22	1	183	69	93	102	2.6	24.39	0.70	0	1	1	1	0	1
109	41	1	234	72	134	144	3.3	25.85	0.80	0	1	1	2	1	2
110	30	2	132	39	86	44	3.4	29.24	0.88	0	1	1	1	1	1
111	48	1	176	48	110	90	3.7	26.23	0.83	0	0	2	2	1	2
112	49	1	170	39	90	206	4.4	25.47	0.79	0	0	2	1	1	2
113	41	2	179	49	116	73	3.7	23.18	0.86	0	1	1	1	0	1
114	26	2	119	49	62	44	2.4	20.21	0.78	0	0	1	1	0	1

Anexo 2 – Conjunto dos dados submetidos a rede e resultado treinamento.

IDA	SEX	CT	HDL	LDL	TG	CT/HDL	IMC	ICQ	FU	DM	HAS	RC	RC-RN	% DIF
44	1	207	56	141	49	3.7	28.50	0.75	0	0	1	1	1.03	2.91
43	1	232	66	155	57	3.5	25.68	0.78	0	1	1	2	1.98	-1.01
55	1	262	41	176	225	6.4	24.54	0.95	0	0	2	3	2.99	-0.33
48	1	219	68	129	110	3.2	24.53	0.75	0	1	2	2	1.96	-2.04
55	1	206	56	133	84	3.7	26.24	0.81	0	1	1	2	1.96	-2.04
43	1	186	41	128	80	4.5	29.07	0.80	0	1	2	2	2.03	1.48
38	2	235	39	164	164	6.1	34.17	0.98	1	0	2	3	2.99	-0.33
64	1	233	55	150	139	4.2	27.69	0.92	0	2	1	3	3	✓
46	1	193	47	125	106	4.1	28.84	0.80	0	1	1	1	1.03	2.91
27	1	199	83	106	48	2.4	21.99	0.77	0	0	1	1	1	✓
44	1	191	48	128	72	3.9	27.85	0.80	0	2	1	1	1	✓
46	2	256	43	184	145	5.9	29.91	0.91	0	0	2	2	2.03	1.48
51	1	242	47	178	83	5.2	30.33	0.88	0	0	1	2	1.82	-9.89
53	2	195	33	137	127	6.0	29.59	0.95	1	0	1	3	3	✓
49	1	214	52	146	77	4.1	25.91	0.84	0	1	1	2	1.98	-1.01
24	1	187	80	92	72	2.3	20.44	0.73	1	1	1	1	1	✓
20	1	188	72	98	89	2.6	19.72	0.71	0	0	1	1	1	✓
23	1	164	87	65	64	1.9	20.83	0.68	0	0	1	1	1	✓
28	1	168	71	88	44	2.4	22.15	0.84	0	1	2	1	1	✓
42	1	126	50	0	44	2.5	21.99	0.75	0	1	1	1	1	✓
23	1	163	65	0	44	2.5	20.70	0.66	0	0	1	1	1	✓
44	1	190	38	139	67	5.0	21.50	0.83	1	0	1	1	1.01	0.99
41	1	283	56	162	324	5.1	36.95	0.84	0	0	2	3	3.01	0.33
31	1	99	72	0	44	0.0	28.51	0.71	1	0	1	1	1	✓
38	1	163	68	86	47	2.4	32.89	0.91	0	0	2	1	1.02	1.96
18	2	99	44	0	54	0.0	20.30	0.81	0	1	1	1	1	✓
45	1	159	36	90	165	4.4	37.66	0.94	0	1	2	2	2.04	1.96
52	2	178	53	109	79	3.3	30.47	0.91	0	0	1	2	2.04	1.96
44	1	189	68	110	54	2.8	20.57	0.73	0	0	2	2	1.96	-2.04
30	1	132	49	75	44	2.7	20.20	0.74	1	0	1	1	1	✓
46	1	175	61	98	81	2.9	18.99	0.77	0	1	1	1	1.02	1.96
43	1	150	40	90	102	3.8	22.94	0.83	1	0	1	2	1.92	-4.17
50	1	189	92	91	44	2.1	21.11	0.88	0	1	1	1	1	✓
36	2	104	25	37	212	4.2	23.15	0.91	1	0	1	2	2.01	0.50
27	2	113	37	66	44	3.0	22.77	0.76	0	1	1	1	1	✓
51	1	167	48	90	148	3.5	29.96	0.81	1	1	1	1	1.07	6.54
33	1	188	47	124	81	4.0	29.37	0.76	0	1	1	1	1	✓
33	2	139	42	82	79	3.3	23.81	0.86	0	0	1	1	1	✓
41	1	160	60	80	99	2.7	26.31	0.72	0	1	2	1	1.08	7.41
40	1	157	46	94	89	3.4	21.81	0.75	1	1	1	2	1.99	-0.50
48	2	189	44	115	147	4.3	27.21	0.94	0	1	2	2	2.05	2.44
21	1	131	35	79	90	3.8	27.17	0.83	0	1	1	1	1	✓
45	1	228	70	140	91	3.3	21.01	0.65	0	1	1	2	1.98	-1.01
53	1	134	46	66	108	2.9	35.38	0.84	0	2	2	3	3	✓
49	2	187	33	122	158	5.6	24.32	0.89	0	1	1	2	2.09	4.31
41	1	172	31	113	143	5.6	23.50	0.78	0	0	1	1	1.01	0.99
36	2	194	43	118	164	4.5	25.86	0.87	0	1	1	1	1.04	3.85
48	2	218	43	155	96	5.1	22.82	0.88	0	1	1	2	2.05	2.44
48	1	164	45	94	126	3.7	20.62	0.77	0	1	1	2	2.01	0.50
42	1	171	56	93	113	3.1	29.27	0.79	0	1	2	2	1.96	-2.04
49	1	219	67	117	175	3.3	26.25	0.78	0	1	2	2	2	✓
31	1	180	57	100	115	3.1	19.78	0.78	0	1	1	1	1	✓
36	1	160	62	88	52	2.6	22.19	0.76	0	1	1	1	1	✓
43	1	193	45	125	114	4.3	29.15	0.79	0	2	1	1	1	✓
40	1	225	100	0	53	0.0	22.81	0.70	0	1	1	2	1.88	-6.38
37	1	133	43	79	54	3.1	27.34	0.85	1	1	1	1	1	✓
48	1	192	47	131	66	4.1	38.95	0.78	0	1	1	1	1	✓
39	1	202	71	0	44	2.8	22.48	0.69	0	1	1	1	1	✓
37	1	207	60	136	57	3.5	21.48	0.74	0	1	1	1	1	✓
49	1	223	63	116	220	3.6	33.12	0.89	0	2	2	3	2.99	-0.33
43	1	181	48	121	60	3.8	24.50	0.82	1	1	1	2	2.01	0.50
47	2	178	26	128	122	6.9	23.88	0.95	1	0	2	3	3	✓
39	2	220	41	134	222	5.4	24.01	0.87	0	1	2	2	2.03	1.48
45	1	192	63	107	111	3.1	25.43	0.77	0	1	1	1	1.1	9.09
34	1	178	82	82	69	2.2	22.22	0.78	0	0	1	1	1	✓
33	2	172	35	113	123	5.0	25.00	0.84	0	0	1	1	1	✓
20	1	133	46	76	51	2.9	28.77	0.83	0	1	1	1	1	✓
40	1	185	53	112	99	3.5	22.94	0.85	1	0	1	2	1.86	-7.53
50	1	256	66	180	48	3.9	20.62	0.74	0	1	1	3	2.96	-1.35

46	1	262	34	177	257	7.7	29.90	0.79	0	0	2	3	2.99	-0.33
60	2	161	46	106	49	3.5	20.45	0.80	0	1	2	3	2.89	-3.81
47	1	167	63	94	51	2.6	20.23	0.84	0	1	1	1	1	✓
41	1	212	39	142	156	5.4	30.78	0.80	0	0	1	2	1.91	-4.71
42	1	179	56	113	52	3.2	20.78	0.80	1	1	1	2	1.98	-1.01
47	1	191	56	99	182	3.4	31.53	0.82	0	2	2	2	2.01	0.50
48	1	223	34	154	179	6.6	36.39	0.83	1	1	2	3	3.01	0.33
35	1	189	52	113	124	3.6	20.37	0.80	0	1	1	1	1	✓
28	1	157	68	81	44	2.3	20.66	0.72	0	1	1	1	1	✓
39	1	247	42	181	116	5.8	25.25	0.84	0	0	1	1	1	✓
52	1	207	43	150	75	4.9	37.92	0.85	0	0	2	3	3	✓
42	1	183	47	119	86	3.9	32.67	0.74	0	1	1	1	1	✓
36	1	223	53	158	55	4.2	26.29	0.82	0	1	1	1	1	✓
50	1	227	100	0	62	0.0	20.45	0.77	1	2	2	3	3	✓
41	1	218	60	122	184	3.6	33.15	0.75	0	0	1	2	1.96	-2.04
48	1	181	33	131	86	5.5	29.00	0.94	0	1	2	2	1.98	-1.01
47	1	188	69	100	94	2.7	28.76	0.85	0	1	1	1	1	✓
42	1	189	43	117	144	4.4	22.95	0.83	0	1	1	1	1.05	4.76
45	1	219	44	157	88	5.0	29.76	0.90	0	1	2	2	1.99	-0.50
18	2	145	34	98	62	4.2	21.05	0.75	0	1	2	1	1	✓
42	1	178	34	134	49	5.3	27.78	0.79	1	0	2	2	1.98	-1.01
51	1	306	39	133	166	7.8	35.44	0.84	0	2	2	4	3.87	-3.36
48	1	172	48	109	74	3.6	34.24	0.86	0	1	2	3	2.95	-1.69
48	1	194	49	130	75	4.0	35.70	0.91	0	1	2	3	2.95	-1.69
64	2	186	38	124	121	4.9	25.91	0.90	0	2	2	3	2.96	-1.35
28	1	167	60	96	58	2.8	31.64	0.80	0	0	1	1	1	✓
28	1	99	42	0	44	0.0	22.38	0.73	0	0	1	1	1	✓
26	2	184	35	125	116	5.2	28.70	0.87	0	1	1	1	1	✓
41	1	187	60	118	44	3.1	22.23	0.71	0	1	1	1	1.04	3.85
46	2	207	51	134	113	4.1	26.17	0.91	0	1	1	2	2.02	0.99
52	1	183	50	119	73	3.7	28.76	0.92	0	1	2	3	3.01	0.33
54	1	170	60	94	79	2.8	19.56	0.78	0	1	2	3	2.88	-4.17
50	1	133	51	66	78	2.6	16.36	0.77	0	1	1	2	2.02	0.99
21	1	214	72	130	58	3.0	26.84	0.75	0	1	1	1	1	✓
42	1	174	61	106	44	2.8	28.67	0.79	0	0	1	1	1	✓
37	2	177	49	109	98	3.7	26.28	0.82	0	0	1	1	1.02	1.96
42	1	188	71	101	80	2.6	22.60	0.85	0	1	1	1	1	✓
22	1	183	69	93	102	2.6	24.39	0.70	0	1	1	1	1	✓
41	1	234	72	134	144	3.3	25.85	0.80	0	1	1	2	1.97	-1.52
30	2	132	39	86	44	3.4	29.24	0.88	0	1	1	1	1	✓
48	1	176	48	110	90	3.7	26.23	0.83	0	0	2	2	1.89	-5.82
49	1	170	39	90	206	4.4	25.47	0.79	0	0	2	2	1.93	-3.63
41	2	179	49	116	73	3.7	23.18	0.86	0	1	1	1	1.02	1.96
26	2	119	49	62	44	2.4	20.21	0.78	0	0	1	1	1	✓
													Desvio médio	2.40 %
													Número acertos	40
													% Acertos	44 %
													Número erros	63
													% Erros	56 %
													Distorção	-0.091

n.	IDA	S	CT	HDL	LDL	TG	RDC	FLS	% DIF
60	49	1	0.710949502625004	0.00000000002804	0.141851064900488	0.999876605424014	3	4.9	38.64
61	43	1	0.000008293750374	0.000004329734519	0.310025518872388	0.00000000102619	2	3.8	47.71
62	47	2	0.000003372003864	0.999806492352899	0.645656306225795	0.000024915388939	3	3.9	24.00
63	39	2	0.500000000000000	0.003334807307413	0.858148935099512	0.999917282777148	2	3.9	48.37
64	45	1	0.000224816770233	0.00000000002804	0.026596993576866	0.000002760764950	1	2.8	63.92
66	34	1	0.000003372003864	0.000000000000000	0.000184071904963	0.00000000620808	1	1.8	43.86
67	33	2	0.000000557390059	0.500000000000000	0.083172696493922	0.000030431556901	1	1.8	45.79
68	20	1	0.00000000004623	0.000028947435320	0.000055448524723	0.00000000016963	1	2.8	64.61
69	40	1	0.000027535691115	0.000000037459704	0.069138420343347	0.000000250451575	2	2.8	29.81
70	50	1	0.999979600912720	0.00000000000162	0.999983298578152	0.00000000009309	3	2.7	-9.64
71	46	1	0.999996627996136	0.721115178022863	0.999969568443099	0.999999924565422	3	2.8	-7.69
72	60	2	0.00000020558322	0.000028947435320	0.021881270936131	0.00000000011370	3	2.8	-5.26
73	47	1	0.000000124370587	0.00000000002804	0.002025320389050	0.00000000016963	1	2.8	64.82
74	41	1	0.083172696493922	0.021881270936131	0.967704535301550	0.021881270936131	2	1.8	-11.34
75	42	1	0.000004551723745	0.000000002166831	0.083172696493922	0.00000000020718	2	3.8	47.30
76	47	1	0.000166558064777	0.000000002166831	0.005486298899450	0.802183888558582	2	4.8	58.51
77	48	1	0.710949502625004	0.721115178022863	0.996981583675292	0.689974481127613	3	4.8	37.93
78	35	1	0.000091415873852	0.000000096859913	0.083172696493922	0.000037168937103	1	2.8	64.34
79	28	1	0.00000006192048	0.000000000000024	0.000150710358060	0.00000000004183	1	2.7	63.28
80	39	1	0.999696552969971	0.001292349776287	0.999986325990915	0.000007504501597	1	1.8	45.66
81	52	1	0.019840305734078	0.000500201107080	0.993307149075715	0.000000002061154	3	2.9	-5.26
82	42	1	0.000015112095441	0.000011195359505	0.231475216500982	0.000000018601939	1	2.7	63.52
83	36	1	0.710949502625004	0.000000037459704	0.998641480049571	0.000000000037751	1	2.8	64.59
84	50	1	0.890903178804387	0.000000000000000	0.000000000013888	0.00000000153089	3	5.8	48.01
85	41	1	0.354343693774205	0.00000000048474	0.354343693774205	0.858148935099512	2	1.8	-14.15
86	48	1	0.000008293750374	0.869891525637002	0.768524783499018	0.000000018601939	2	3.9	49.19
87	47	1	0.000067724149620	0.000000000000009	0.006692850924285	0.000000092136000	1	2.8	64.86
88	42	1	0.000091415873852	0.000500201107080	0.167981614866076	0.002025320389050	1	2.8	64.71
89	45	1	0.425557483188341	0.000193507647101	0.998341198919826	0.000000027750832	2	3.9	48.72
90	18	2	0.000000000169190	0.721115178022863	0.004496273160941	0.00000000153089	1	3.8	73.33
91	42	1	0.000003372003864	0.721115178022863	0.858148935099512	0.00000000011370	2	3.8	47.17
92	51	1	0.99999999993760	0.021881270936131	0.832018385133924	0.141851064900488	4	4.8	17.38
93	48	1	0.000000557390059	0.000004329734519	0.039165722796764	0.000000001687530	3	3.9	22.25
94	48	1	0.000409567164986	0.000001674490406	0.731058578630005	0.000000002061154	3	3.9	23.26
95	64	2	0.000037168937103	0.054681317215941	0.450166002687522	0.000020399087280	3	4.9	38.78
96	28	1	0.000000124370587	0.000000000048474	0.003018416324708	0.000000000068787	1	1.8	44.44
97	28	1	0.000000000000000	0.001292349776287	0.000000000013888	0.00000000004183	1	1.7	42.20
98	26	2	0.000020399087280	0.500000000000000	0.500000000000000	0.000007504501597	1	2.9	65.20
99	41	1	0.000050172164684	0.00000000048474	0.197816111441418	0.00000000004183	1	2.7	63.10
100	46	2	0.019840305734078	0.000000250451575	0.858148935099512	0.000004118571745	2	2.9	31.16
101	52	1	0.000015112095441	0.000000647594798	0.231475216500982	0.000000001381633	3	3.9	23.40
102	54	1	0.000000305902227	0.00000000048474	0.002025320389050	0.000000004587182	3	3.8	20.64
103	50	1	0.00000000004623	0.000000250451575	0.000007504501597	0.000000003755667	2	2.8	27.80
104	21	1	0.141851064900488	0.000000000000001	0.731058578630005	0.000000000068787	1	2.8	63.64
105	42	1	0.00001015630439	0.00000000018747	0.021881270936131	0.00000000004183	1	1.8	44.28
106	37	2	0.00002498044086	0.000001674490406	0.039165722796764	0.000000205052416	1	1.8	45.15
107	42	1	0.000067724149620	0.000000000000001	0.008162571153160	0.000000005602796	1	2.8	64.86
108	22	1	0.000015112095441	0.000000000000009	0.001658801080174	0.000000456352429	1	2.7	62.91
109	41	1	0.985225968306727	0.000000000000001	0.858148935099512	0.002025320389050	2	2.8	28.57
110	30	2	0.00000000003425	0.021881270936131	0.000409567164986	0.00000000004183	1	2.9	65.33
111	48	1	0.000001850597773	0.000004329734519	0.047425873177567	0.000000041399375	2	2.8	29.26
112	49	1	0.000000305902227	0.021881270936131	0.000911051194401	0.997974679610950	2	2.8	28.21
113	41	2	0.000004551723745	0.000001674490406	0.141851064900488	0.000000001381633	1	2.9	64.98
114	26	2	0.000000000000069	0.000001674490406	0.000003372003864	0.00000000004183	1	1.8	43.86
						Número acertos			0
						% Acertos			0%
						Número erros			113
						% Erros			100%
						Diferença Média			56%

Anexo 5 – Rotina para classificar a avaliação de risco dos dados.

```

*****
* Programa: AVALIA.PRG
* Data...: 27-03-2002
* Função..: Avaliar o grau de risco no resultado dos exames
* Analista: Aldir Roberto Perozin
*****

use exames                && abre o banco de dados
go top                    && posiciona o ponteiro no primeiro registro
do while !eof()           && executa enquanto não chegar a fim
  if sex=[2]              && condição se for igual a masculino
    if val(tri)<150.and.val(ttl)<200.and.val(ldl)<100.and.val(hdl)>40
      ** R1 tabela padrão
      repl ris with [1]
    endif
    if(val(tri)>=150.and.val(tri)<=199).and.(val(ttl)>=200.and.;
val(ttl)<=239).and.(val(ldl)>=100.and.val(ldl)<=149).and.;
      val(hdl)>=30.and.val(hdl)<=40)
      ** R2 tabela padrão
      repl ris with [2]
    endif
    if val(tri)>=200.and.val(ttl)>=240.and.val(ldl)>=150.and.;
      val(hdl)<=30
      ** R3 tabela padrão
      repl ris with [3]
    endif
  else
    if val(tri)<150.and.val(ttl)<200.and.val(ldl)<100.and.val(hdl)>45
      ** R1 tabela padrão
      repl ris with [1]
    endif
    if (val(tri)>=150.and.val(tri)<=199).and.(val(ttl)>=200.and.;
val(ttl)<=239).and.(val(ldl)>=100.and.val(ldl)<=149).and.;
      val(hdl)>=35.and.val(hdl)<=45)
      ** R2 tabela padrão
      repl ris with [2]
    endif
    if val(tri)>=200.and.val(ttl)>=240.and.val(ldl)>=150.and.;
      val(hdl)<=35
      ** R3 tabela padrão
      repl ris with [3]
    endif
  endif
  skip                    && avança um registro
enddo

*****
* EOF : AVALIA.PRG
*****

```


Anexo 6 – Resultados dos estudos com o conjunto de dados.

		Estudo 1		Estudo 2		Estudo 3		Estudo 4		Estudo 5	
Topologia da Rede		12 15 1		12 12 1		12 12 1		12 12 1		6 7 1	
n.	RDC	RN-N	% DIF	RN-B	% DIF	RN-SZ	% DIF	RN-FS	% DIF	RN-L	% DIF
1	1	1.07	6.54	1.03	2.91	1.05	4.76	1.02	1.961	1.29	22.48
2	2	2.07	3.38	1.98	-1.01	1.96	-2.04	1.97	-1.523	2.33	14.16
3	3	3.19	5.96	2.99	-0.33	2.99	-0.33	2.99	-0.334	3.54	15.25
4	2	1.77	-12.99	1.96	-2.04	2.01	0.50	1.95	-2.564	2.18	8.26
5	2	2.05	2.44	1.96	-2.04	2.06	2.91	1.95	-2.564	2	*
6	2	1.88	-6.38	2.03	1.48	2.02	0.99	1.97	-1.523	1.28	-56.25
7	3	2.85	-5.26	2.99	-0.33	3.2	6.25	3.05	1.639	2.95	-1.69
8	3	2.95	-1.69	3	*	3.02	0.66	3.06	1.961	2.76	-8.70
9	1	1.12	10.71	1.03	2.91	1.09	8.26	1.01	0.99	1.35	25.93
10	1	1	*	1	*	1	*	1	*	1	*
11	1	1	*	1	*	1	*	1	*	1.24	19.35
12	2	1.87	-6.95	2.03	1.48	2.08	3.85	2.05	2.439	2.21	9.50
13	2	2.15	6.98	1.82	-9.89	2.01	0.50	1.92	-4.167	2.59	22.78
14	3	3.01	0.33	3	*	3.03	9.09	3.07	2.28	3.14	4.46
15	2	1.95	-2.56	1.98	-1.01	1.98	-1.01	1.99	-0.503	1.47	-36.05
16	1	1.02	1.96	1	*	1	*	1	*	1	*
17	1	1	*	1	*	1	*	1	*	1	*
18	1	1	*	1	*	1	*	1.01	0.99	1	*
19	1	1	*	1	*	1	*	1	*	1	*
20	1	1	*	1	*	1.06	5.66	1	*	1.06	5.66
21	1	1	*	1	*	1	*	1.02	1.961	1.02	1.96
22	1	1.04	3.85	1.01	0.99	1.03	2.91	1.01	0.99	1.17	14.53
23	3	2.95	-1.69	3.01	0.33	2.98	-0.67	2.99	-0.334	3.17	5.36
24	1	1	*	1	*	1	*	1	*	1	*
25	1	1.01	0.99	1.02	1.96	1.05	4.76	1.03	2.913	1	*
26	1	1	*	1	*	1	*	1	*	1.1	9.09
27	2	1.76	-13.64	2.04	1.96	1.73	-15.61	1.93	-3.627	1.86	-7.53
28	2	1.5	-33.33	2.04	1.96	2.06	2.91	2	*	2.09	4.31
29	2	1.65	-21.21	1.96	-2.04	2	*	1.9	-5.263	1.05	-90.48
30	1	1.01	0.99	1	*	1.08	7.41	1	*	1	*
31	1	1.16	13.79	1.02	1.96	1.11	9.91	1.11	9.91	1.11	9.91
32	2	1.96	-2.04	1.92	-4.17	2.01	0.50	2.04	1.961	2.23	10.31
33	1	1.01	0.99	1	*	1.02	1.96	1	*	1	*
34	2	1.82	-9.89	2.01	0.50	2.04	1.96	1.96	-2.041	1.45	-37.93
35	1	1	*	1	*	1	*	1	*	1	*
36	1	1.12	10.71	1.07	6.54	1.11	9.91	1.04	3.846	1.95	48.72
37	1	1	*	1	*	1	*	1	*	1	*
38	1	1	*	1	*	1	*	1.01	0.99	1.14	12.28
39	1	1.05	4.76	1.08	7.41	1.05	4.76	1.04	3.846	1	*
40	2	1.92	-4.17	1.99	-0.50	2.05	2.44	2.04	1.961	1.02	-96.08
41	2	1.61	-24.22	2.05	2.44	2.08	3.85	2.04	1.961	1.37	-45.99
42	1	1	*	1	*	1	*	1	*	1	*
43	2	1.75	-14.29	1.98	-1.01	2.22	9.91	1.93	-3.627	2.79	28.32
44	3	2.6	-15.38	3	*	3.18	5.66	3.05	1.639	3.03	0.99
45	2	1.53	-30.72	2.09	4.31	2.05	2.44	2.1	4.762	2.03	1.48
46	1	1.06	5.66	1.01	0.99	1.08	7.41	1.01	0.99	1.26	20.63
47	1	1.03	2.91	1.04	3.85	1	*	1.01	0.99	1.33	24.81
48	2	1.54	-29.87	2.05	2.44	2.06	2.91	2.04	1.961	1.36	-47.06
49	2	1.97	-1.52	2.01	0.50	2.03	1.48	1.98	-1.01	2.23	10.31
50	2	1.6	-25.00	1.96	-2.04	2	*	1.96	-2.041	1.05	-90.48
51	2	1.73	-15.61	2	*	2.11	5.21	1.93	-3.627	3.02	33.77
52	1	1.01	0.99	1	*	1	*	1	*	1	*
53	1	1	*	1	*	1	*	1	*	1	*
54	1	1	*	1	*	1	*	1	*	1.4	28.57
55	2	1.59	-25.79	1.88	-6.38	2	*	1.93	-3.627	2.8	28.57
56	1	1.03	2.91	1	*	1.01	0.99	1	*	1	*
57	1	1	*	1	*	1	*	1.01	0.99	2.3	56.52
58	1	1.01	0.99	1	*	1.05	4.76	1	*	1.32	24.24
59	1	1.04	3.85	1	*	1.01	0.99	1	*	1.01	0.99
60	3	2.5	-20.00	2.99	-0.33	2.94	-2.04	3.01	0.332	3.42	12.28
61	2	1.96	-2.04	2.01	0.50	1.97	-1.52	1.96	-2.041	1.17	-70.94
62	3	2.49	-20.48	3	*	3.25	7.69	2.99	-0.334	3.32	9.64
63	2	1.59	-25.79	2.03	1.48	1.84	-8.70	2.03	1.478	2.62	23.66
64	1	1.07	6.54	1.1	9.09	1.03	2.91	1	*	1.23	18.70
66	1	1	*	1	*	1	*	1.02	1.961	1	*

Topologia da Rede		Estudo 1		Estudo 2		Estudo 3		Estudo 4		Estudo 5	
n.	RDC	RN-N	% DIF	RN-B	% DIF	RN-SZ	% DIF	RN-FS	% DIF	RN-L	% DIF
67	1	1.03	2.91	1	*	1	*	1	*	1.13	11.50
68	1	1	*	1	*	1	*	1	*	1	*
69	2	1.87	-6.95	1.86	-7.53	1.89	-5.82	2.03	1.478	1.1	-81.82
70	3	2.69	-11.52	2.96	-1.35	2.93	-2.39	3.02	0.662	3.25	7.69
71	3	3.07	2.28	2.99	-0.33	2.91	-3.09	2.98	-0.671	3.47	13.54
72	3	2.89	-3.81	2.95	-1.69	3.16	5.06	3	*	3.07	2.28
73	1	1.07	6.54	1	*	1.04	3.85	1	*	1.06	5.66
74	2	1.94	-3.09	1.91	-4.71	1.75	-14.29	1.96	-2.041	2.67	25.09
75	2	1.91	-4.71	1.98	-1.01	1.91	-4.71	2	*	1.05	-90.48
76	2	1.68	-19.05	2.01	0.50	1.82	-9.89	1.93	-3.627	1.53	-30.72
77	3	3.38	11.24	3.01	0.33	2.99	-0.33	3	*	3.23	7.12
78	1	1.03	2.91	1	*	1.02	1.96	1	*	1	*
79	1	1	*	1	*	1	*	1	*	1	*
80	1	1.09	8.26	1	*	1.08	7.41	1.02	1.961	1.35	25.93
81	3	2.63	-14.07	3	*	2.95	-1.69	3	*	3.34	10.18
82	1	1	*	1	*	1	*	1	*	1.14	12.28
83	1	1.07	6.54	1	*	1.05	4.76	1.05	4.762	1	*
84	3	2.38	-26.05	3	*	2.97	-1.01	3.05	1.639	3.15	4.76
85	2	1.89	-5.82	1.96	-2.04	2.03	1.48	1.91	-4.712	2.81	28.83
86	2	1.91	-4.71	1.98	-1.01	1.86	-7.53	1.92	-4.167	2.24	10.71
87	1	1.04	3.85	1	*	1.03	2.91	1	*	1.12	10.71
88	1	1.16	13.79	1.05	4.76	1.1	9.09	1	*	1.56	35.90
89	2	1.95	-2.56	1.99	-0.50	1.92	-4.17	1.93	-3.627	2.14	6.54
90	1	1.01	0.99	1	*	1	*	1	*	1	*
91	2	2.01	0.50	1.98	-1.01	1.92	-4.17	2.04	1.961	1	*
92	4	3.93	-1.78	3.87	-3.36	3.96	-1.01	3.95	-1.266	3.56	-12.36
93	3	3.04	1.32	2.95	-1.69	3.01	0.33	2.93	-2.389	2.95	-1.69
94	3	3.1	3.23	2.95	-1.69	2.98	-0.67	3.01	0.332	1.59	-88.68
95	3	2.91	-3.09	2.96	-1.35	3.04	1.32	2.98	-0.671	3.66	18.03
96	1	1	*	1	*	1	*	1	*	1	*
97	1	1.01	0.99	1	*	1.01	0.99	1.01	0.99	1	*
98	1	1	*	1	*	1	*	1	*	1	*
99	1	1.01	0.99	1.04	3.85	1.01	0.99	1.01	0.99	1.03	2.91
100	2	1.62	-23.46	2.02	0.99	2.01	0.50	2.02	0.99	1.35	-48.15
101	3	3.04	1.32	3.01	0.33	3.07	2.28	3	*	3.44	12.79
102	3	2.76	-8.70	2.88	-4.17	3.08	2.60	2.91	-3.093	2.7	-11.11
103	2	2.03	1.48	2.02	0.99	2.07	3.38	1.95	-2.564	1.79	-11.73
104	1	1	*	1	*	1	*	1	*	1	*
105	1	1.01	0.99	1	*	1	*	1.01	0.99	1.01	0.99
106	1	1.02	1.96	1.02	1.96	1.03	2.91	1.01	0.99	1.28	21.88
107	1	1.02	1.96	1	*	1.03	2.91	1	*	1.01	0.99
108	1	1	*	1	*	1	*	1	*	1	*
109	2	2.06	2.91	1.97	-1.52	2.04	1.96	1.97	-1.523	2.23	10.31
110	1	1	*	1	*	1	*	1	*	1.01	0.99
111	2	1.85	-8.11	1.89	-5.82	2	*	1.84	-8.696	2.15	6.98
112	2	2.01	0.50	1.93	-3.63	2	*	1.91	-4.712	1.48	-35.14
113	1	1.06	5.66	1.02	1.96	1.03	2.91	1.02	1.961	1.33	24.81
114	1	1	*	1	*	1	*	1.01	0.99	1	*
Média de erro		-3.89		-0.06		1.51		-0.08		-2.31	
Número acertos exatos		26		50		36		41		29	
% Acertos exatos		23%		44%		32%		36%		26%	
Número acertos ± 5%		82		97		87		111		70	
% acertos ± 5%		73%		86%		77%		98%		62%	
% acertos ± 10%		95%		100%		97%		99%		50%	
Distorção		-0.965		-0.091		-1.039		0.046		-1.474	

*Anexo 7 – Resultados do conjunto de dados de treinamento e teste.***CONJUNTO DE DADOS DE TREINAMENTO (80 registros)**

IDA	SEX	CT	HDL	LDL	TG	CT/HDL	IMC	ICQ	FU	DM	HAS	RDC	RN	% DIF
44	1	207	56	141	49	3.7	28.50	0.75	0	0	1	1	1.06	5.66
43	1	232	66	155	57	3.5	25.68	0.78	0	1	1	2	2.03	1.48
55	1	262	41	176	225	6.4	24.54	0.95	0	0	2	3	3.18	5.66
48	1	219	68	129	110	3.2	24.53	0.75	0	1	2	2	1.83	-9.29
55	1	206	56	133	84	3.7	26.24	0.81	0	1	1	2	2.09	4.31
43	1	186	41	128	80	4.5	29.07	0.80	0	1	2	2	1.83	-9.29
38	2	235	39	164	164	6.1	34.17	0.98	1	0	2	3	3.02	0.66
64	1	233	55	150	139	4.2	27.69	0.92	0	2	1	3	2.95	-1.69
46	1	193	47	125	106	4.1	28.84	0.80	0	1	1	1	1.08	7.41
27	1	199	83	106	48	2.4	21.99	0.77	0	0	1	1	1	*
44	1	191	48	128	72	3.9	27.85	0.80	0	2	1	1	1.01	0.99
46	2	256	43	184	145	5.9	29.91	0.91	0	0	2	2	1.91	-4.71
51	1	242	47	178	83	5.2	30.33	0.88	0	0	1	2	2.06	2.91
53	2	195	33	137	127	6.0	29.59	0.95	1	0	1	3	2.99	-0.33
49	1	214	52	146	77	4.1	25.91	0.84	0	1	1	2	2.03	1.48
24	1	187	80	92	72	2.3	20.44	0.73	1	1	1	1	1.03	2.91
20	1	188	72	98	89	2.6	19.72	0.71	0	0	1	1	1	*
23	1	164	87	65	64	1.9	20.83	0.68	0	0	1	1	1	*
28	1	168	71	88	44	2.4	22.15	0.84	0	1	2	1	1.03	2.91
42	1	126	50	0	44	2.5	21.99	0.75	0	1	1	1	1.01	0.99
23	1	163	65	0	44	2.5	20.70	0.66	0	0	1	1	1	*
44	1	190	38	139	67	5.0	21.50	0.83	1	0	1	1	1.07	6.54
41	1	283	56	162	324	5.1	36.95	0.84	0	0	2	3	3.15	4.76
31	1	99	72	0	44	0.0	28.51	0.71	1	0	1	1	1	*
38	1	163	68	86	47	2.4	32.89	0.91	0	0	2	1	1.01	0.99
18	2	99	44	0	54	0.0	20.30	0.81	0	1	1	1	1	*
45	1	159	36	90	165	4.4	37.66	0.94	0	1	2	2	1.85	-8.11
52	2	178	53	109	79	3.3	30.47	0.91	0	0	1	2	2.09	4.31
44	1	189	68	110	54	2.8	20.57	0.73	0	0	2	2	1.85	-8.11
30	1	132	49	75	44	2.7	20.20	0.74	1	0	1	1	1.03	2.91
46	1	175	61	98	81	2.9	18.99	0.77	0	1	1	1	1.04	3.85
43	1	150	40	90	102	3.8	22.94	0.83	1	0	1	2	1.99	-0.50
50	1	189	92	91	44	2.1	21.11	0.88	0	1	1	1	1.01	0.99
36	2	104	25	37	212	4.2	23.15	0.91	1	0	1	2	2.06	2.91
27	2	113	37	66	44	3.0	22.77	0.76	0	1	1	1	1	*
51	1	167	48	90	148	3.5	29.96	0.81	1	1	1	1	1.05	4.76
33	1	188	47	124	81	4.0	29.37	0.76	0	1	1	1	1	*
33	2	139	42	82	79	3.3	23.81	0.86	0	0	1	1	1	*
41	1	160	60	80	99	2.7	26.31	0.72	0	1	2	1	1.06	5.66
40	1	157	46	94	89	3.4	21.81	0.75	1	1	1	2	1.95	-2.56
48	2	189	44	115	147	4.3	27.21	0.94	0	1	2	2	1.92	-4.17
21	1	131	35	79	90	3.8	27.17	0.83	0	1	1	1	1	*
45	1	228	70	140	91	3.3	21.01	0.65	0	1	1	2	1.98	-1.01
53	1	134	46	66	108	2.9	35.38	0.84	0	2	2	3	2.98	-0.67
49	2	187	33	122	158	5.6	24.32	0.89	0	1	1	2	2.08	3.85
41	1	172	31	113	143	5.6	23.50	0.78	0	0	1	1	1.04	3.85
36	2	194	43	118	164	4.5	25.86	0.87	0	1	1	1	1.04	3.85
48	2	218	43	155	96	5.1	22.82	0.88	0	1	1	2	2.17	7.83
48	1	164	45	94	126	3.7	20.62	0.77	0	1	1	2	2.57	22.18
42	1	171	56	93	113	3.1	29.27	0.79	0	1	2	2	1.84	-8.70
49	1	219	67	117	175	3.3	26.25	0.78	0	1	2	2	1.86	-7.53
31	1	180	57	100	115	3.1	19.78	0.78	0	1	1	1	1	*
36	1	160	62	88	52	2.6	22.19	0.76	0	1	1	1	1	*
43	1	193	45	125	114	4.3	29.15	0.79	0	2	1	1	1.02	1.96
40	1	225	100	0	53	0.0	22.81	0.70	0	1	1	2	1.86	-7.53
37	1	133	43	79	54	3.1	27.34	0.85	1	1	1	1	1.04	3.85
48	1	192	47	131	66	4.1	38.95	0.78	0	1	1	1	1	*
39	1	202	71	0	44	2.8	22.48	0.69	0	1	1	1	1.02	1.96
37	1	207	60	136	57	3.5	21.48	0.74	0	1	1	1	1.01	0.99
49	1	223	63	116	220	3.6	33.12	0.89	0	2	2	3	2.87	-4.53
43	1	181	48	121	60	3.8	24.50	0.82	1	1	1	2	1.92	-4.17
47	2	178	26	128	122	6.9	23.88	0.95	1	0	2	3	2.86	-4.90
39	2	220	41	134	222	5.4	24.01	0.87	0	1	2	2	1.96	-2.04
45	1	192	63	107	111	3.1	25.43	0.77	0	1	1	1	1.05	4.76
34	1	178	82	82	69	2.2	22.22	0.78	0	0	1	1	1	*

IDA	SEX	CT	HDL	LDL	TG	CT/HDL	IMC	ICQ	FU	DM	HAS	RDC	RN	% DIF
33	2	172	35	113	123	5.0	25.00	0.84	0	0	1	1	1.01	0.99
20	1	133	46	76	51	2.9	28.77	0.83	0	1	1	1	1	*
40	1	185	53	112	99	3.5	22.94	0.85	1	0	1	2	1.94	-3.09
50	1	256	66	180	48	3.9	20.62	0.74	0	1	1	3	2.85	-5.26
46	1	262	34	177	257	7.7	29.90	0.79	0	0	2	3	3.01	0.33
60	2	161	46	106	49	3.5	20.45	0.80	0	1	2	3	2.65	-1.69
47	1	167	63	94	51	2.6	20.23	0.84	0	1	1	1	1	*
41	1	212	39	142	156	5.4	30.78	0.80	0	0	1	2	2.04	1.96
42	1	179	56	113	52	3.2	20.78	0.80	1	1	1	2	1.89	-5.82
47	1	191	56	99	182	3.4	31.53	0.82	0	2	2	2	1.9	-5.26
48	1	223	34	154	179	6.6	36.39	0.83	1	1	2	3	3	*
35	1	189	52	113	124	3.6	20.37	0.80	0	1	1	1	1.01	0.99
28	1	157	68	81	44	2.3	20.66	0.72	0	1	1	1	1	*
39	1	247	42	181	116	5.8	25.25	0.84	0	0	1	1	1.1	9.09
52	1	207	43	150	75	4.9	37.92	0.85	0	0	2	3	3	*

Margem de erro	0.53
Número de acertos exatos	19
% Acertos exatos	24%
Número de acertos ± 5%	68
% acertos ± 5%	85%
% acertos ± 10%	99%
Distorção	0.675

CONJUNTO DE DADOS DE TESTE (33 registros)

IDA	SEX	CT	HDL	LDL	TG	CT/HDL	IMC	ICQ	FU	DM	HAS	RDC	RN	% DIF
42	1	183	47	119	86	3.9	32.67	0.74	0	1	1	1	1	*
36	1	223	53	158	55	4.2	26.29	0.82	0	1	1	1	1	*
50	1	227	100	0	62	0.0	20.45	0.77	1	2	2	3	3.02	0.66
41	1	218	60	122	184	3.6	33.15	0.75	0	0	1	2	2.01	0.50
48	1	181	33	131	86	5.5	29.00	0.94	0	1	2	2	1.97	-1.52
47	1	188	69	100	94	2.7	28.76	0.85	0	1	1	1	1	*
42	1	189	43	117	144	4.4	22.95	0.83	0	1	1	1	1.02	1.96
45	1	219	44	157	88	5.0	29.76	0.90	0	1	2	2	2	*
18	2	145	34	98	62	4.2	21.05	0.75	0	1	2	1	1	*
42	1	178	34	134	49	5.3	27.78	0.79	1	0	2	2	2.01	0.50
51	1	306	39	133	166	7.8	35.44	0.84	0	2	2	4	3.97	-0.76
48	1	172	48	109	74	3.6	34.24	0.86	0	1	2	3	2.98	-0.67
48	1	194	49	130	75	4.0	35.70	0.91	0	1	2	3	2.97	-1.01
64	2	186	38	124	121	4.9	25.91	0.90	0	2	2	3	2.97	-1.01
28	1	167	60	96	58	2.8	31.64	0.80	0	0	1	1	1	*
28	1	99	42	0	44	0.0	22.38	0.73	0	0	1	1	1.01	0.99
26	2	184	35	125	116	5.2	28.70	0.87	0	1	1	1	1	*
41	1	187	60	118	44	3.1	22.23	0.71	0	1	1	1	1	*
46	2	207	51	134	113	4.1	26.17	0.91	0	1	1	2	1.99	-0.50
52	1	183	50	119	73	3.7	28.76	0.92	0	1	2	3	3.02	0.66
54	1	170	60	94	79	2.8	19.56	0.78	0	1	2	3	3	*
50	1	133	51	66	78	2.6	16.36	0.77	0	1	1	2	2.02	0.99
21	1	214	72	130	58	3.0	26.84	0.75	0	1	1	1	1	*
42	1	174	61	106	44	2.8	28.67	0.79	0	0	1	1	1	*
37	2	177	49	109	98	3.7	26.28	0.82	0	0	1	1	1	*
42	1	188	71	101	80	2.6	22.60	0.85	0	1	1	1	1	*
22	1	183	69	93	102	2.6	24.39	0.70	0	1	1	1	1	*
41	1	234	72	134	144	3.3	25.85	0.80	0	1	1	2	2.02	0.99
30	2	132	39	86	44	3.4	29.24	0.88	0	1	1	1	1	*
48	1	176	48	110	90	3.7	26.23	0.83	0	0	2	2	2	*
49	1	170	39	90	206	4.4	25.47	0.79	0	0	2	2	2	*
41	2	179	49	116	73	3.7	23.18	0.86	0	1	1	1	1.01	0.99
26	2	119	49	62	44	2.4	20.21	0.78	0	0	1	1	1	*

Margem de erro 0.18
Número de acertos exatos 18
% Acertos exatos 55%
Número de acertos ± 5% 33
% acertos ± 5% 100%
% acertos ± 10% 100%
Distorção -0.176

8.1 – CONJUNTO DE DADOS ANALISADO PELA REDE NEURAL E DETERMINAÇÃO PELA LÓGICA FUZZY DO DE RISCO DE DAC.

RN1 * 5	RN2*10	RN3*20	RNS4*40	RN5*70	RN1	RN2	RN3	RN4	RN5	Risco	RDC	n.
4.4995	1.0010	*	*	*	0.8999	0.1001	*	*	*	5.5%	1	1
*	9.0000	2.0260	*	7.0490	*	0.9	0.1013	*	0.1007	16.4%	2	2
*	*	17.9880	*	*	*	*	0.8994	*	*	20.0%	3	3
*	9.0000	*	*	*	*	0.9	*	*	*	10.0%	2	4
*	9.0000	*	*	7.0140	*	0.9	*	*	0.1002	16.0%	2	5
*	8.9210	2.0020	*	*	*	0.8921	0.1001	*	*	11.0%	2	6
0.5285	*	17.9960	4.3880	7.0070	0.1057	*	0.8998	0.1097	0.1001	24.6%	3	7
*	1.0020	18.0000	4.0520	*	*	0.1002	0.9	0.1013	*	20.9%	3	8
4.5000	*	2.0640	*	7.1890	0.9	*	0.1032	*	0.1027	12.4%	1	9
4.4995	1.0590	*	*	*	0.8999	0.1059	*	*	*	5.5%	1	10
4.5000	*	*	*	*	0.9	*	*	*	*	5.0%	1	11
*	9.0000	*	*	*	*	0.9	*	*	*	10.0%	2	12
*	9.0000	*	*	7.0210	*	0.9	*	*	0.1003	16.0%	2	13
0.8545	4.4670	9.2380	4.6840	7.6020	0.1709	0.4467	0.4619	0.1171	0.1086	20.6%	3	14
*	9.0000	*	*	7.0210	*	0.9	*	*	0.1003	16.0%	2	15
4.5000	*	*	*	*	0.9	*	*	*	*	5.0%	1	16
4.5000	*	*	*	*	0.9	*	*	*	*	5.0%	1	17
4.5000	1.0080	*	*	*	0.9	0.1008	*	*	*	5.5%	1	18
4.5000	*	*	*	*	0.9	*	*	*	*	5.0%	1	19
4.5000	*	*	*	*	0.9	*	*	*	*	5.0%	1	20
4.5000	*	*	*	*	0.9	*	*	*	*	5.0%	1	21
4.4415	1.1480	*	*	*	0.8883	0.1148	*	*	*	5.6%	1	22
*	*	17.8760	*	*	*	*	0.8938	*	*	20.0%	3	23
4.5000	*	*	*	*	0.9	*	*	*	*	5.0%	1	24
4.4970	*	*	*	*	0.8994	*	*	*	*	5.0%	1	25
4.5000	*	*	*	*	0.9	*	*	*	*	5.0%	1	26
*	9.0000	2.1620	*	*	*	0.9	0.1081	*	*	11.1%	2	27
*	8.9660	*	*	*	*	0.8966	*	*	*	10.0%	2	28
*	9.0000	*	*	*	*	0.9	*	*	*	10.0%	2	29
4.5000	*	*	*	*	0.9	*	*	*	*	5.0%	1	30
4.4960	1.0010	*	*	*	0.8992	0.1001	*	*	*	5.5%	1	31
0.5125	8.9490	*	4.2040	7.1470	0.1025	0.8949	*	0.1051	0.1021	17.3%	2	32
4.5000	*	*	*	*	0.9	*	*	*	*	5.0%	1	33
*	9.0000	*	*	*	*	0.9	*	*	*	10.0%	2	34
4.5000	*	*	*	*	0.9	*	*	*	*	5.0%	1	35
4.4950	*	*	*	7.0350	0.899	*	*	*	0.1005	11.5%	1	36
4.5000	1.0020	*	*	*	0.9	0.1002	*	*	*	5.5%	1	37
4.5000	*	*	*	*	0.9	*	*	*	*	5.0%	1	38
*	9.0000	*	*	*	*	0.9	*	*	*	10.0%	1	39
0.5080	8.9860	*	4.2080	7.1330	0.1016	0.8986	*	0.1052	0.1019	17.3%	2	40
0.5030	9.0000	*	*	*	0.1006	0.9	*	*	*	9.5%	2	41
4.5000	*	*	*	*	0.9	*	*	*	*	5.0%	1	42
*	9.0000	2.0260	*	7.0350	*	0.9	0.1013	*	0.1005	16.4%	2	43
*	*	18.0000	*	*	*	*	0.9	*	*	20.0%	3	44
0.5025	8.9970	*	*	*	0.1005	0.8997	*	*	*	9.5%	2	45
4.5000	*	*	*	*	0.9	*	*	*	*	5.0%	1	46
4.4920	1.0070	*	*	*	0.8984	0.1007	*	*	*	5.5%	1	47
0.5030	8.9970	*	*	*	0.1006	0.8997	*	*	*	9.5%	2	48
*	9.0000	*	*	*	*	0.9	*	*	*	10.0%	2	49
*	8.9810	2.0020	*	*	*	0.8981	0.1001	*	*	11.0%	2	50
*	9.0000	*	*	*	*	0.9	*	*	*	10.0%	2	51
4.5000	*	*	*	*	0.9	*	*	*	*	5.0%	1	52
4.5000	*	*	*	7.0070	0.9	*	*	*	0.1001	11.5%	1	53
4.4995	*	*	4.0040	*	0.8999	*	*	0.1001	*	8.5%	1	54
0.5005	8.9990	2.0760	*	7.0350	0.1001	0.8999	0.1038	*	0.1005	15.5%	2	55
4.5000	*	*	*	*	0.9	*	*	*	*	5.0%	1	56
4.5000	*	*	*	*	0.9	*	*	*	*	5.0%	1	57
4.5000	*	*	*	7.0420	0.9	*	*	*	0.1006	11.5%	1	58
4.5000	*	*	*	*	0.9	*	*	*	*	5.0%	1	59
*	1.2090	17.6020	4.0240	*	*	0.1209	0.8801	0.1006	*	20.7%	3	60
0.5090	8.9650	*	4.2400	7.1540	0.1018	0.8965	*	0.106	0.1022	17.3%	2	61
*	*	*	4.0360	*	*	*	*	0.1009	*	40.0%	3	62
*	9.0000	*	*	*	*	0.9	*	*	*	10.0%	2	63
4.4990	1.0040	*	*	7.0070	0.8998	0.1004	*	*	0.1001	11.4%	1	64
4.4955	1.1240	*	*	*	0.8991	0.1124	*	*	*	5.6%	1	66

RN1 * 5	RN2*10	RN3*20	RNS4*40	RN5*70	RN1	RN2	RN3	RN4	RN5	Risco	RDC	n.
4.5000	*	*	*	*	0.9	*	*	*	*	5.0%	1	67
4.5000	*	*	*	*	0.9	*	*	*	*	5.0%	1	68
0.5030	8.9870	*	4.3440	7.1610	0.1006	0.8987	*	0.1086	0.1023	17.3%	2	69
0.5005	*	17.9560	*	7.0490	0.1001	*	0.8978	*	0.1007	23.2%	3	70
*	*	17.7920	*	*	*	*	0.8896	*	*	20.0%	3	71
*	1.0160	17.9980	*	*	*	0.1016	0.8999	*	*	19.0%	3	72
4.4645	1.0050	*	*	*	0.8929	0.1005	*	*	*	5.5%	1	73
*	9.0000	2.0320	*	7.0490	*	0.9	0.1016	*	0.1007	16.4%	2	74
0.5005	8.9070	*	4.2000	7.1050	0.1001	0.8907	*	0.105	0.1015	17.3%	2	75
*	1.0010	2.3320	*	*	*	0.1001	0.1166	*	*	15.4%	2	76
*	*	*	4.0320	*	*	*	*	0.1008	*	40.0%	3	77
4.5000	*	*	*	*	0.9	*	*	*	*	5.0%	1	78
4.5000	1.0090	*	*	*	0.9	0.1009	*	*	*	5.5%	1	79
4.5000	1.0130	*	*	7.0210	0.9	0.1013	*	*	0.1003	11.4%	1	80
*	1.0070	17.9980	*	*	*	0.1007	0.8999	*	*	19.0%	3	81
4.5000	*	*	*	*	0.9	*	*	*	*	5.0%	1	82
4.5000	1.0010	*	*	*	0.9	0.1001	*	*	*	5.5%	1	83
*	*	18.0000	*	7.0770	*	*	0.9	*	0.1011	25.0%	3	84
*	9.0000	2.0420	*	7.0420	*	0.9	0.1021	*	0.1006	16.4%	2	85
*	8.9990	*	*	*	*	0.8999	*	*	*	10.0%	2	86
4.5000	*	*	*	7.0070	0.9	*	*	*	0.1001	11.5%	1	87
4.4945	1.0120	*	4.0040	7.3360	0.8989	0.1012	*	0.1001	0.1048	14.0%	1	88
*	8.9350	2.0020	*	*	*	0.8935	0.1001	*	*	11.0%	2	89
4.4995	*	*	*	*	0.8999	*	*	*	*	5.0%	1	90
0.5180	*	*	4.0040	*	0.1036	*	*	0.1001	*	22.2%	2	91
*	1.0010	2.1400	*	*	*	0.1001	0.107	*	*	15.2%	4	92
*	1.0080	17.9980	*	*	*	0.1008	0.8999	*	*	19.0%	3	93
*	1.0080	17.9980	*	*	*	0.1008	0.8999	*	*	19.0%	3	94
*	*	17.9900	*	*	*	*	0.8995	*	*	20.0%	3	95
4.5000	*	*	*	*	0.9	*	*	*	*	5.0%	1	96
4.5000	*	*	*	*	0.9	*	*	*	*	5.0%	1	97
4.5000	*	*	*	*	0.9	*	*	*	*	5.0%	1	98
4.5000	1.0010	*	*	*	0.9	0.1001	*	*	*	5.5%	1	99
*	9.0000	*	*	*	*	0.9	*	*	*	10.0%	2	100
*	*	17.9920	*	*	*	*	0.8996	*	*	20.0%	3	101
*	*	17.9580	*	*	*	*	0.8979	*	*	20.0%	3	102
0.5480	8.8900	*	*	*	0.1096	0.889	*	*	*	9.5%	2	103
4.5000	1.0010	*	*	*	0.9	0.1001	*	*	*	5.5%	1	104
4.5000	*	*	*	*	0.9	*	*	*	*	5.0%	1	105
4.5000	*	*	*	*	0.9	*	*	*	*	5.0%	1	106
4.5000	*	*	*	7.0420	0.9	*	*	*	0.1006	11.5%	1	107
4.5000	1.0190	*	*	*	0.9	0.1019	*	*	*	5.5%	1	108
*	9.0000	2.0360	*	7.0420	*	0.9	0.1018	*	0.1006	16.4%	2	109
4.5000	*	2.0200	*	*	0.9	*	0.101	*	*	6.5%	1	110
*	8.8850	2.0020	*	*	*	0.8885	0.1001	*	*	11.0%	2	111
*	9.0000	*	*	*	*	0.9	*	*	*	10.0%	2	112
4.4995	1.0070	*	*	*	0.8999	0.1007	*	*	*	5.5%	1	113
4.5000	*	*	*	*	0.9	*	*	*	*	5.0%	1	114

Anexo 9 – Glossário de Cardiologia

Acidente vascular cerebral (AVC): Doença de início súbito, caracterizada pela falta de irrigação sanguínea em um determinado território cerebral. Pode ser secundário à oclusão de alguma artéria ou a um sangramento, no último caso é denominado Acidente Vascular Cerebral Hemorrágico.

Angina Pectoris: É o termo médico em latim que significa dor no peito, causada pela pouca irrigação de sangue do músculo do coração. Nome dado à dor que antecede ao infarto. Nem todas as vezes que surgem dores no peito é um prenúncio de infarto. A dor no peito suspeita é aquela que surge depois de esforços físicos; dura poucos minutos e vai embora.

Anovulação: Alteração no funcionamento dos ovários, capaz de alterar a produção, maturação ou liberação normal de óvulos. Esta alteração pode ser intencional (como a induzida pelas pílulas anticoncepcionais) ou ser endógena. Pode ser uma causa de infertilidade.

Arteriosclerose: É o mesmo que aterosclerose. Envolve o depósito de gorduras (colesterol) cálcio, fibrina na camada interna das artérias. Palavra de origem grega que significa artérias endurecidas.

Ataque cardíaco: Nome popular do Infarto do Miocárdio.

Aterosclerose: É o mesmo de arteriosclerose. Envolve o depósito de gorduras (colesterol), cálcio, fibrina na camada interna das artérias. Palavra de origem grega que significa artérias endurecidas

Ateroma ou Placa: É a formação, dentro da artéria, que estreita a passagem do sangue. É o que constitui-se na aterosclerose ou arteriosclerose

Bile: Líquido secretado pelo fígado e acumulado na vesícula biliar, com abundante quantidade de bilirrubina, colesterol e pigmentos biliares. Tem importante função na digestão de gorduras. É lançada na porção inicial do intestino delgado através de um conduto chamado hepato-colédoco.

Cardiopatia: Doença do coração. Pode ser congênita ou adquirida

Cardiopatia isquêmica: Doença ocasionada por um déficit na circulação nas artérias coronarianas e outros defeitos capazes de afetar o aporte sanguíneo para o músculo cardíaco. É evidenciada por dor no peito (ver angina do peito), arritmias, morte súbita ou insuficiência cardíaca.

Diabetes Mellitus: Distúrbio metabólico originado da incapacidade das células de incorporar glicose. De forma secundária, podem estar afetados o metabolismo de gorduras e proteínas. Este distúrbio é produzido por um déficit absoluto ou relativo de insulina. Suas principais características são aumento da glicose sanguínea (glicemia), poliúria, polidipsia (aumento da ingestão de líquidos) e polifagia (aumento da fome).

Doença Vascular Periférica: As artérias periféricas podem entupir e inflamar. As varizes estão incluídas nesta denominação

ECG: (ver Eletrocardiograma)

Eletrocardiograma: Exame das ondas elétricas do coração. Também abreviado para **ECG**. É feito com 12 derivações (pontos) do peito e das costas.

Esplenomegalia: Aumento tamanho do baço acima dos limites normais.

Exercícios: Uma forma preventiva de combater os fatores de risco de doença arterial cardíaca.

Fatores de risco: São nove condições que predispõem o aparecimento das doenças cardiovasculares e cerebrais: idade, sexo, herança, cigarro e fumaça (fumo passivo), colesterol, pressão arterial alta, inatividade (falta de exercícios), obesidade e diabetes.

HDL: Abreviatura utilizada para denominar um tipo de proteína encarregada de transportar o colesterol sanguíneo, que se relaciona com menor risco cardiovascular. Também é conhecido como "Bom Colesterol". Seus valores normais são de 35-50mg/dl.

Hemiplegia: Paralisia da metade do corpo. Compromete a metade da face, braço e pernas do mesmo lado. Relaciona-se a infartos, hemorragias ou tumores do sistema nervoso central.

Hipercolesterolemia: Aumento dos níveis de colesterol do sangue. Está associada a uma maior predisposição ao desenvolvimento de aterosclerose, também é chamada de hiperlipidemia.

Hiperlipidemia: Aumento dos lípides (gorduras) do sangue. Os lípides incluem colesterol, esteses do colesterol, fosfolípidos e triglicérides. No sangue estão ligadas às moléculas grandes, chamadas de lipoproteínas. São LDL, HDL e triglicérides.

Hipertireoidismo: Doença caracterizada por um aumento anormal da atividade dos hormônios tireoidianos. Pode ser produzido pela administração externa de hormônios tireoidianos (hipertireoidismo iatrogênico) ou pelo aumento de uma produção destes nas glândulas tireóideas. Seus sintomas, entre outros, são taquicardia, tremores finos, perda de peso, hiperatividade, exoftalmia.

Infarto: Morte de um tecido por irrigação sanguínea insuficiente. O exemplo mais conhecido é o infarto do miocárdio, no qual se produz a obstrução das artérias coronárias com conseqüente lesão irreversível do músculo cardíaco.

Isquemia: Falta de sangue. O infarto do miocárdio causa uma isquemia no coração. O derrame cerebral pode ser isquêmico quando "entope" uma artéria do cérebro e não chega sangue. O derrame cerebral pode ser hemorrágico quando a artéria se rompe e sai o sangue, mas depois dessa ruptura o sangue deixa de circular e também há isquemia.

LDL: (Low Density Lipoprotein) Lipoproteína de baixa densidade, encarregada de transportar colesterol através do sangue. Devido à sua tendência em depositar o colesterol nas paredes arteriais e a produzir aterosclerose, tem sido denominada "mau colesterol".

Lípides: É um termo amplo para designar todas as gorduras do organismo inclusive as do sangue.

Metabolismo: Nome utilizado de forma genérica para se referir ao conjunto de processos

enzimáticos, plásticos e de transformação energética que se produz em cada uma das células do organismo.

Miocárdio: Designação do músculo cardíaco, às vezes é empregado com o significado global incluindo as artérias, válvulas e veias.

Miocardiopatia: Termo utilizado para se referir a doenças que afetam o músculo cardíaco. Suas causas são variadas sendo as mais frequentes a isquemia e a hipertensão. Na América do Sul é importante a infecção pelo *Trypanosoma Cruzi*, causa da miocardiopatia chagásica. Quando não se encontra uma causa para a doença, ela é chamada miocardiopatia idiopática.

Necrose: Conjunto de processos irreversíveis através dos quais se produz a degeneração celular seguida de morte da célula.

Óleos e dieta: A comida deve ser preparada com óleos, que contêm os chamados ácidos graxos (gordurosos) saturados. Os melhores são óleo de milho, girassol, soja etc. Existe oliva, maionese.

Palpitação: Percepção subjetiva dos batimentos cardíacos. Pode apresentar-se durante algumas arritmias cardíacas ou mesmo em pessoas com ritmo normal. Neste último caso, são distúrbios benignos associados a diversos distúrbios de ansiedade.

Placa: Na aterosclerose ou arteriosclerose formam-se depósitos de gordura (colesterol), produtos celulares, cálcio e fibrina na camada interna da artéria (endotélio). Cada um desses depósitos chama-se placa ou ateroma.

Plaqueta: Elemento do sangue (não é uma célula porque não apresenta núcleo) produzido na medula óssea, cuja principal função é participar da coagulação do sangue através da formação de conglomerados que tamponam o escape do sangue por uma lesão em um vaso sanguíneo.

Plasma: Solução na qual se veiculam os diferentes elementos do sangue. É formado principalmente por água na qual se encontram dissolvidos todos os elementos orgânicos e inorgânicos do líquido extracelular (albumina, hormônios, sais minerais, etc.), assim como os elementos figurados (hemácias, leucócitos e plaquetas).

Polisaturado : Uma das três espécies de gordura (ácidos graxos). As outras duas são saturadas e monoinsaturada; somente os óleos que contêm os ácidos graxos saturados é que aumentam o colesterol.

Sedentário: Pessoas que não fazem exercícios. Sedentário significa sentado, sem atividade física.

Sexo: Não há razão para que os pacientes portadores de doença cardiovascular ou cerebral, não façam sexo. O uso de Viagra e a atividade sexual deve ser coordenada com a medicação e o controle médico. Há medicamentos que diminuem a potência sexual, mas o medo, depressão e o estado emocional são os mais graves fatores de disfunção erétil no homem

Taquicardia: Aumento da frequência cardíaca. Pode ser devido a causas fisiológicas (durante o exercício físico ou gravidez) ou por diversas doenças como sepse, hipertireoidismo e anemia. Pode ser assintomática ou provocar palpitações.

Triglicérides: É um dos componentes gordurosos das lipoproteínas junto com os fosfolípides.

Trombo: Nome de um coágulo que se forma no interior da artéria, da veia ou da cavidade do coração, que pode ser enviado pela corrente sanguínea e pela taquicardia para entupir algum vaso no cérebro, no pulmão, no olho etc, que chama-se trombose. A distância do trombo pode ser denominado também de embolo.

Tromboembolismo: Doença produzida pela impactação de um fragmento de um trombo. É produzida quando este se desprende de seu lugar de origem, e é levado pela corrente sanguínea até produzir a oclusão de uma artéria distante do local de origem do trombo. Esta oclusão pode ter diversas conseqüências, desde leves até fatais, dependendo do tamanho do vaso ocluído e do tipo de circulação do órgão onde se deu a oclusão.

Trombose: Formação de trombos no interior de um vaso sanguíneo. Pode ser venosa ou arterial e produzem diferentes sintomas segundo os territórios afetados. A trombose de uma artéria coronariana pode produzir um infarto do miocárdio.

Anexo 10 – Tabelas de avaliação de risco de DAC de Framingham.

FRAMINGHAM

Risco Coronário - Homens

AVALIAÇÃO 1		IDADE
IDADE	LDL Pts	Col Pts
30-34	-1	[-1]
35-39	0	[0]
40-44	1	[1]
45-49	2	[2]
50-54	3	[3]
55-59	4	[4]
60-64	5	[5]
65-69	6	[6]
70-74	7	[7]

AVALIAÇÃO 1		LDL-C
(mg/dL)	(mmol/L)	LDL Pts
< 100	< 2,59	-3
100-129	2,60-3,36	0
130-159	3,37-4,14	0
160-190	4,15-4,92	1
>= 190	>=4,92	2

[OU]		Coolesterol
(mg/dL)	(mmol/L)	Col Pts
< 160	< 4,14	[-3]
160-199	4,15-5,17	[0]
200-239	5,18-6,21	[1]
240-279	6,22-7,24	[2]
>= 280	>=7,25	[3]

RISCO RELATIVO	
MUITO BAIXO	
BAIXO	
MODERADO	
ALTO	
MUITO ALTO	

AVALIAÇÃO 3		HDL-c	
(mg/dL)	(mmol/L)	LDL Pts	Col Pts
< 35	< 0,90	2	[2]
35-44	0,91-1,16	1	[1]
45-49	1,17-1,29	0	[0]
50-59	1,30-1,55	0	[0]
>= 60	>= 1,56	-1	[-2]

AVALIAÇÃO 4 PRESSÃO ARTERIAL				
Sistólica (mmHg)	Diastólica (mmHg)			
	< 80	80-84	85-89	90-99 >=100
< 120	0 [0] Pts			
120-129	0 [0] Pts			
130-139	1 [1] Pts			
140-159	2 [2] Pts			
>= 160	3 [3] Pts			

Nota: quando a PA sistólica ou diastólica apresentar diferente estimativa de risco, use o maior número.

AVALIAÇÃO 5 DIABETES		AVALIAÇÃO 6 - FUMO	
LDL Pts	Col Pts	LDL Pts	Col Pts
Não 0	[0]	Não 0	[0]
Sim 2	[2]	Sim 2	[2]

AVALIAÇÃO 7	PONTUAÇÃO
Idade	
LDL-c ou Col	
HDL-c	
Pressão Arterial	
Diabetes	
Fumo	
Pontuação total	

AVALIAÇÃO 3		RISCO DE DAC	
LDL Pts	10 Anos	Col Pts	10 Anos
Total	Risco DAC	Total	Risco DAC
< -3	1%		
-2	2%		
-1	2%	[< -1]	[2%]
0	3%	[0]	[3%]
1	4%	[1]	[3%]
2	4%	[2]	[4%]
3	6%	[3]	[5%]
4	7%	[4]	[7%]
5	9%	[5]	[8%]
6	11%	[6]	[10%]
7	14%	[7]	[13%]
8	18%	[8]	[16%]
9	22%	[9]	[20%]
10	27%	[10]	[25%]
11	33%	[11]	[31%]
12	40%	[12]	[37%]
13	47%	[13]	[45%]
>= 14	>= 56%	[>=14]	[>=53%]

AVALIAÇÃO 9 COMPARAÇÃO DO RISCO			
idade anos	média 10-a Risco DAC	alta 10-a Risco DAC	baixa 10-a Risco DAC
30-34	3%	1%	2%
35-39	5%	4%	3%
40-44	7%	4%	4%
45-49	11%	8%	4%
50-54	14%	10%	6%
55-59	16%	13%	7%
60-64	21%	20%	9%
65-69	25%	22%	11%
70-74	30%	25%	14%

* Risco estimado derivado da experiência do Framingham Heart Study em uma população predominantemente caucasiana em Massachusetts, EUA.

* Alto risco de DAC exclui *angina pectoris*; * baixo risco foi calculado para pessoas da mesma idade, ótima pressão arterial, LDL-c 100-129 mg/dL ou

colesterol 160-199 mg/dL, HDL-c 45 mg/dL, não fumante e sem diabetes. Pts = pontos. 10-a = 10 anos

Wilson PWF *et al*, *Circulation* 1998; 97: 1837-47.

FRAMINGHAM

Risco Coronário - Mulheres

AVALIAÇÃO 1		IDADE
IDADE	LDL Pts	Col Pts
30-34	-9	[-9]
35-39	-4	[-4]
40-44	0	[0]
45-49	3	[3]
50-54	6	[6]
55-59	7	[7]
60-64	8	[8]
65-69	8	[8]
70-74	8	[8]

AVALIAÇÃO 1		LDL-C
(mg/dL)	(mmol/L)	LDL Pts
< 100	< 2,59	-2
100-129	2,60-3,36	0
130-159	3,37-4,14	0
160-190	4,15-4,92	2
>= 190	>=4,92	2

[OU]		Colesterol
(mg/dL)	(mmol/L)	Col Pts
< 160	< 4,14	[-2]
160-199	4,15-5,17	[0]
200-239	5,18-6,21	[0]
240-279	6,22-7,24	[2]
>= 280	>=7,25	[2]

RISCO RELATIVO	
MUITO BAIXO	
BAIXO	
MODERADO	
ALTO	
MUITO ALTO	

AVALIAÇÃO 3		HDL-c	
(mg/dL)	(mmol/L)	LDL Pts	Col Pts
< 35	< 0,90	5	[5]
35-44	0,91-1,16	2	[2]
45-49	1,17-1,29	1	[1]
50-59	1,30-1,55	0	[0]
>= 60	>= 1,56	-2	[-3]

AVALIAÇÃO 4		PRESSÃO ARTERIAL				
Sistólica (mmHg)	Diastólica (mmHg)	< 80	80-84	85-89	90-99	>= 100
< 120		0	[0]	Pts		
120-129		0	[0]	Pts		
130-139		1	[1]	Pts		
140-159		2	[2]	Pts		
>= 160		3	[3]	Pts		

Nota: quando a PA sistólica ou diastólica apresentar diferente estimativa de risco, use o maior número.

AVALIAÇÃO 5 DIABETES		AVALIAÇÃO 6 - FUMO			
LDL Pts	Col Pts	LDL Pts	Col Pts		
Não	0	[0]	Não	0	[0]
Sim	4	[4]	Sim	2	[2]

AVALIAÇÃO 7	PONTUAÇÃO
Idade	
LDL-c ou Col	
HDL-c	
Pressão Arterial	
Diabetes	
Fumo	
Pontuação total	

AVALIAÇÃO 3		RISCO DE DAC	
LDL Pts	10 Anos	Col Pts	10 Anos
Total	Risco DAC	Total	Risco DAC
< -2	1%	[< -2]	[1%]
-1	2%	[-1]	[2%]
0	2%	[0]	[2%]
1	2%	[1]	[2%]
2	3%	[2]	[3%]
3	3%	[3]	[3%]
4	4%	[4]	[4%]
5	5%	[5]	[4%]
6	6%	[6]	[5%]
7	7%	[7]	[6%]
8	8%	[8]	[7%]
9	9%	[9]	[8%]
10	11%	[10]	[10%]
11	13%	[11]	[11%]
12	15%	[12]	[13%]
13	17%	[13]	[15%]
14	20%	[14]	[18%]
15	24%	[15]	[20%]
16	27%	[16]	[24%]
>= 17	>= 32%	[>=17]	[>=27%]

AVALIAÇÃO 9 COMPARAÇÃO DO RISCO			
idade anos	média 10-a Risco DAC	alta 10-a Risco DAC	baixa 10-a Risco DAC
30-34	<1%	<1%	1%
35-39	<1%	<1%	1%
40-44	2%	1%	2%
45-49	5%	2%	3%
50-54	8%	3%	5%
55-59	12%	7%	7%
60-64	12%	8%	8%
65-69	13%	8%	8%
70-74	14%	11%	8%

* Risco estimado derivado da experiência do Framingham Heart Study em uma população predominantemente caucasiana em Massachusetts, EUA.

* Alto risco de DAC exclui *angina pectoris*; * baixo risco foi calculado para pessoas da mesma idade, ótima pressão arterial, LDL-c 100-129 mg/dL ou

colesterol 160-199 mg/dL, HDL-C 45 mg/dL, não fumante e sem diabetes. Pts = pontos. 10-a = 10 anos

Wilson PWF *et al*, *Circulation* 1998; 97: 1837-47.