

MAURICIO CONCEIÇÃO MARIO

**Modelo de análise de variáveis craniométricas através das Redes Neurais
Artificiais Paraconsistentes**

Tese apresentada à Faculdade de Medicina da
Universidade de São Paulo para obtenção do título de
Doutor em Ciências

Área de concentração: Fisiopatologia Experimental
Orientador: Prof. Dr. Jair Minoro Abe
Co-orientadora: Profa. Dra. Neli Regina Siqueira Ortega

São Paulo
2006

MAURICIO CONCEIÇÃO MARIO

**Modelo de análise de variáveis craniométricas através das Redes Neurais
Artificiais Paraconsistentes**

Tese apresentada à Faculdade de Medicina da
Universidade de São Paulo para obtenção do título de
Doutor em Ciências

Área de concentração: Fisiopatologia Experimental
Orientador: Prof. Dr. Jair Minoro Abe
Co-orientadora: Profa. Dra. Neli Regina Siqueira Ortega

São Paulo
2006

Dedicatória

Dedico este trabalho a meus pais e meus filhos, que me apoiaram e tiveram comigo a paciência necessária nos momentos em que estive ausente, por conta deste.

Agradecimentos

Agradeço ao Prof. Dr. Marinho Del Santo Jr., incansável no trabalho de aprimorar a metodologia para análise cefalométrica, participando diariamente, e não medindo esforços para que fosse concluído com êxito, além de sugerir o tema da tese.

Agradeço ao Prof. Dr. Jair Minoru Abe por sempre acreditar que fosse possível a concepção desse trabalho, e por ter me acolhido para implementá-lo, além de sua inestimável ajuda com a Lógica Paraconsistente.

Agradeço à Profa. Dra. Neli Regina Siqueira Ortega por ter sido decisiva nos momentos em que precisávamos definir os rumos deste trabalho, e também por ter me apoiado durante todo esse período, nos menores, e nos mais importantes detalhes.

Agradeço ao Prof. Dr. Cássio Selaimen, Doutor em Ortodontia pela UNESP, campus de Araraquara, e ao Prof. Dr. Roberto Brandão, Doutor em Ortodontia pela UNESP, campus de Araraquara e professor da Universidade Federal do Espírito Santo, pela avaliação dos diagnósticos ortodônticos, para que pudéssemos fazer a análise de concordância com o modelo desenvolvido.

Agradeço à estudante de Ortodontia da UNESP, campus de Araraquara, Srta. Thaís Parisotto, pela sua ajuda em coletar dados relativos às variáveis craniométricas de pacientes.

Agradeço ao Prof. Dr. Eduardo Massad, da Faculdade de Medicina da USP, por ter me aceito inicialmente como seu orientando, sem o que não seria possível o nosso trabalho. Também agradeço ao Prof. Dr. João Inácio da Silva Filho por sua colaboração com os conceitos da Lógica Paraconsistente.

O autor.

Esta tese está de acordo com:

Referências: adaptado de *International Committee of Medical Journals Editors* (Vancouver).

Universidade de São Paulo. Faculdade de Medicina. Serviço de Biblioteca e Documentação. *Guia de apresentação de dissertações, teses e monografias*. Elaborado por Anneliese Carneiro da Cunha, Maria Julia de A. L. Freddi, Maria F. Crestana, Marinalva de Souza Aragão, Suely Campos Cardoso, Valéria Vilhena. São Paulo: Serviço de Biblioteca e Documentação; 2004.

Abreviaturas dos títulos dos periódicos de acordo com *List of Journals Indexed In Index Medicus*.

SUMÁRIO

Lista de abreviaturas

Lista de figuras

Lista de tabelas

Resumo

Summary

1	INTRODUÇÃO	01
1.1	Análise cefalométrica	02
1.2	Variáveis craniométricas.....	04
1.3	Análise cefalométrica e o uso de técnicas de Inteligência Artificial para o diagnóstico ortodôntico	11
1.4	Inteligência Artificial	12
1.5	Resumo histórico das Redes Neurais Artificiais	16
1.6	Características das Redes Neurais Artificiais	18
1.7	Sistemas Especialistas	21
1.8	Inteligência Artificial e Redes Neurais Artificiais na atualidade	23
1.9	Lógica Paraconsistente	24
1.9.1	Lógica Paraconsistente Anotada	26
1.9.2	Lógica Paraconsistente Anotada de anotação com dois valores	31
1.9.3	Análise da Lógica Paraconsistente Anotada de anotação com dois valores	32
1.9.4	Representação do quadrado unitário no plano cartesiano	33

1.9.5	Algoritmo Para-analisador simplificado	36
1.9.6	Célula Artificial Paraconsistente básica	37
1.9.7	Célula Neural Artificial Paraconsistente.....	39
1.9.8	Célula Neural Artificial Paraconsistente básica	40
1.9.9	Unidades Neurais Artificiais Paraconsistentes	41
1.9.10	Estrutura de uma Rede Neural Artificial Paraconsistente	42
1.9.11	Célula Neural Artificial Paraconsistente de aprendizagem	43
1.9.12	Célula Neural Artificial Paraconsistente de Conexão Lógica analítica ...	44
1.10	Técnicas de Inteligência Artificial aplicadas à análise cefalométrica	46
2	OBJETIVOS	48
2.1	Objetivos	49
3	METODOLOGIA	50
3.1	Rede Neural Artificial Paraconsistente e análise cefalométrica	51
3.2	Estrutura das Unidades Neurais Artificiais Paraconsistentes.....	52
3.3	Módulo de normalização	54
3.3.1	Metodologia usada para determinação do grau de evidência de uma variável craniométrica	56
3.4	Módulo de caracterização das funções de evidências.....	59
3.5	Módulo de aprendizagem.....	62
3.6	Módulo de evidência	64
3.7	Módulo de diagnóstico	66

3.7.1	Sistema de regras da unidade I – discrepância anteroposterior	66
3.7.2	Sistema de regras da unidade II – discrepância esquelética vertical	67
3.7.3	Sistema de regras da unidade III – alterações dentárias	68
3.8	Análise da performance do sistema	69
3.8.1	Caracterização dos casos utilizados.....	71
4	RESULTADOS	73
4.1	Resultados obtidos com o modelo de análise cefalométrica.....	74
4.2	Resultados da discrepância anteroposterior	74
4.3	Resultados da avaliação da discrepância vertical	75
4.4	Resultados da avaliação das alterações dentárias	76
4.5	Concordância entre as avaliações dos especialistas	77
5	DISCUSSÃO	79
5.1	Análise dos resultados	80
5.2	Análise dos resultados obtidos na região anteroposterior	80
5.3	Análise dos resultados do posicionamento da maxila e da mandíbula	82
5.4	Análise dos resultados da discrepância vertical	84
5.5	Análise dos resultados do posicionamento dos incisivos superiores	85
5.6	Análise dos resultados do posicionamento dos incisivos inferiores	88
5.7	Análise dos resultados do ângulo entre os incisivos	90

6	CONCLUSÕES	91
6.1	Modelo de análise cefalométrica utilizado como apoio ao diagnóstico ortodôntico	92
6.2	Limitações do modelo de análise cefalométrica.....	93
6.3	Utilização da Lógica Paraconsistente Anotada e outras estruturas de IA	93
7	REFERÊNCIAS BIBLIOGRÁFICAS	97

Apêndice

Apêndice 1	Trecho de código do algoritmo que armazena variáveis craniométricas normais
Apêndice 2	Trecho de código do algoritmo que atribui valores diferentes de desvio padrão
Apêndice 3	Código do algoritmo que implementa as regras de diagnóstico da unidade I – maloclusão esquelética anteroposterior
Apêndice 4	Código do algoritmo que implementa as regras de diagnóstico da unidade II – discrepância esquelética vertical
Apêndice 5	Código do algoritmo que implementa as regras de diagnóstico da unidade III – alterações dentárias
Apêndice 6	Instruções de uso do programa de análise cefalométrica

Lista de abreviaturas

CNAP:	Célula Neural Artificial Paraconsistente
CAPb:	Célula Artificial Paraconsistente básica
CNAPa:	Célula Neural Artificial Paraconsistente de aprendizagem
CNAPb:	Célula Neural Artificial Paraconsistente básica
CNAPCa:	Célula Neural Artificial Paraconsistente de Conexão Lógica analítica
CNAPCLs:	Célula Neural Artificial Paraconsistente de Conexão Lógica seletiva
CNAPd:	Célula Neural Artificial Paraconsistente de decisão
EEB:	Equação Estrutural Básica
Fa:	Fator de aprendizagem
Gc:	Grau de certeza
Gct:	Grau de contradição
IA:	Inteligência Artificial
LPA:	Lógica Paraconsistente Anotada
LPA2v:	Lógica Paraconsistente Anotada de anotação de 2 valores
QUPC:	Quadrado Unitário do Plano Cartesiano
RNAP:	Rede Neural Artificial Paraconsistente
UNAP:	Unidade Neural Artificial Paraconsistente
Vicc:	Valor inferior de controle de certeza
Vicct:	Valor inferior de controle de contradição
Vscc:	Valor superior de controle de certeza
Vscct:	Valor superior de controle de contradição

Lista de figuras

CAPÍTULO 1

Figura 1.1.	Sobreposição na base do crânio mostrando o crescimento em “raios de sol” entre as idades de 8 e 18 anos.....	04
Figura 1.2.	Pontos cefalométricos que serão utilizados para análise cefalométrica	05
Figura 1.3.	Variáveis craniométricas para análise de discrepâncias esqueléticas anteroposteriores	07
Figura 1.4.	Variáveis craniométricas para análise de discrepâncias esqueléticas verticais	09
Figura 1.5.	Variáveis craniométricas para análise de alterações dentárias.....	10
Figura 1.6.	Esquemático simplificado de partes de uma célula nervosa ou neurônio	19
Figura 1.7.	Modelo de um neurônio artificial típico..	20
Figura 1.8.	Reticulado de “Quatro”.....	30
Figura 1.9.	Reticulado LPA2v.....	32
Figura 1.10.	Representação da Análise Paraconsistente LPA2v.....	33
Figura 1.11.	Quadrado Unitário no Plano Cartesiano	34
Figura 1.12.	Representação dos eixos dos graus de certeza e de contradição ..	36
Figura 1.13.	Esquema da Célula Artificial Paraconsistente básica	38
Figura 1.14.	Célula Neural Artificial Paraconsistente básica	40
Figura 1.15.	Exemplo de Unidades Neurais Artificiais Paraconsistentes formando uma Rede Neural Artificial Paraconsistente	42

Figura 1.16.	Célula Neural Artificial Paraconsistente de aprendizagem	44
Figura 1.17.	Célula Neural Artificial Paraconsistente de Conexão Lógica analítica	45

CAPÍTULO 3

Figura 3.1.	Conexão dos módulos da Rede Neural Artificial Paraconsistente de análise das variáveis craniométricas	54
Figura 3.2.	Esquema da normalização e do cálculo do grau de evidência da variável craniométrica do paciente	57
Figura 3.3.	Célula Neural Artificial Paraconsistente de Conexão Lógica analítica	58
Figura 3.4.	Curva que representa a variação do grau de evidência de uma variável do paciente	59
Figura 3.5.	Formatação das curvas dos graus de evidência	60
Figura 3.6.	Célula Neural Artificial Paraconsistente de aprendizagem	63
Figura 3.7.	Funcionalidade e resposta da rede neural de evidência	65
Figura 3.8.	Modelo de formulário utilizado para diagnóstico dos especialistas	71

Apêndice 6

Figura 6.1.	Acesso ao programa de análise cefalométrica
Figura 6.2.	Interface com o usuário do programa de análise cefalométrica

Lista de tabelas**CAPÍTULO 1**

Tabela 1.1.	Descrição dos pontos cefalométricos utilizados.....	06
-------------	---	----

CAPÍTULO 3

Tabela 3.1.	Interpretação do índice Kappa	70
-------------	-------------------------------------	----

CAPÍTULO 4

Tabela 4.1.	Índice Kappa entre o modelo de análise cefalométrica e os especialistas para avaliação da posição da maxila	74
Tabela 4.2.	Índice Kappa entre o modelo de análise cefalométrica e os especialistas para avaliação da posição da mandíbula	75
Tabela 4.3.	Índice Kappa entre o modelo de análise cefalométrica e os especialistas para avaliação da discrepância anteroposterior	75
Tabela 4.4.	Índice Kappa entre o modelo de análise cefalométrica e os especialistas para avaliação da discrepância vertical	76
Tabela 4.5.	Índice Kappa entre o modelo de análise cefalométrica e os especialistas para avaliação da posição dos incisivos superiores ..	76
Tabela 4.6.	Índice Kappa entre o modelo de análise cefalométrica e os especialistas para avaliação da posição dos incisivos inferiores ...	77
Tabela 4.7.	Índice Kappa entre o modelo de análise cefalométrica e os especialistas para avaliação do ângulo entre os incisivos	77
Tabela 4.8.	Concordância entre os diagnósticos dos especialistas através do índice Kappa	78

RESUMO

Mario MC. *Modelo de análise de variáveis craniométricas através das Redes Neurais Artificiais Paraconsistentes* [tese]. São Paulo: Faculdade de Medicina, Universidade de São Paulo; 2006. 159p.

Este trabalho desenvolve um modelo para análise de variáveis craniométricas que utiliza as Redes Neurais Artificiais Paraconsistentes, assentadas na Lógica Paraconsistente Anotada de dois valores. Tal lógica possui a capacidade de mensurar incerteza, inconsistência e paracompleteza. A Lógica Paraconsistente vem sendo empregada em diversas aplicações sujeitas a estas situações, constituindo nova ferramenta matemática em Inteligência Artificial.

O trabalho tem como principal objetivo melhorar o diagnóstico cefalométrico. O modelo desenvolvido recebe as medidas das variáveis craniométricas de um determinado paciente e as compara com as médias das variáveis craniométricas normais de uma amostra da população brasileira. Esta amostra é composta de crianças e adolescentes de ambos os sexos, na faixa etária de 6 a 18 anos, utilizadas neste trabalho como valores de referência de normalidade.

A análise cefalométrica aqui proposta consiste em quantificar discrepâncias esqueléticas e dentárias sob a Lógica Paraconsistente. O uso das Redes Neurais Artificiais Paraconsistentes permite agregar ao método um fator de incerteza, respeitando o diagnóstico ortodôntico tradicional, e ao mesmo tempo, contextualiza diferentes regiões craniofaciais. O resultado da análise consiste dos graus de discrepância esquelética, anteroposterior e vertical, e graus de discrepância dentárias, relativas aos incisivos inferiores e superiores.

Variáveis craniométricas de 120 pacientes foram processadas pelo modelo proposto e avaliadas por três especialistas em Ortodontia. De acordo com o índice Kappa, houve desde concordância satisfatória até concordância quase perfeita entre o modelo e os especialistas, de acordo com as variáveis consideradas. As opiniões inter-especialista são substancialmente similares às comparações entre os especialistas e o modelo apresentado, o que reflete o potencial do modelo como um sistema especialista.

A utilização de técnicas de Inteligência Artificial através da Lógica Paraconsistente, permitiu significativa melhora na análise cefalométrica proposta. O modelo apresentado pode ser adaptado a outras amostras ou populações, com a adaptação dos valores de referência iniciais de normalidade.

Palavras chave: diagnóstico ortodôntico, variáveis craniométricas, Inteligência Artificial, análise cefalométrica, Lógica Paraconsistente, Redes Neurais Artificiais Paraconsistentes.

SUMMARY

Mario MC. *Analysis of Craniometric Variables throughout Paraconsistent Logic Neural Network* [thesis]. São Paulo: Faculdade de Medicina, Universidade de São Paulo; 2006. 159p.

This work shows the development of an unequal craniometric analysis model, which uses Paraconsistent Neural Network, based upon Paraconsistent Logic with two values. Such logical approach has the capability to handle concepts as uncertainty, inconsistency and paracompleteness. It has been used on diverse applications which present such features, constituting a new mathematical tool in Artificial Intelligence.

The presented methodology had as main goal to booster diagnosis in Orthodontics. The developed model processes craniometric measures of a specific person, and compares to the expected means drawn from a Brazilian sample, comprised of children and adolescent individuals, ranging from 6 to 18 year-old, of both genders.

The current cephalometric analysis, developed under the approach of Paraconsistent Logic, quantifies skeletal and dental discrepancies. The use of Paraconsistent Neural Network allows aggregating a factor of vagueness, respecting the limits of traditional orthodontic classification. At the same time, it contextualizes variables of different craniofacial regions. The results of the analysis are expressed through degrees of skeletal discrepancies, in the anteroposterior and vertical dimensions, and degrees of dental discrepancies, for the upper and lower incisors.

Cephalometric values of a sample of 120 patients were processed by the paraconsistent model and analyzed by three specialists in Orthodontics. According to Kappa index, the agreement between the model and the specialists ranged from moderate to almost perfect, according to the variables considered. The inter-observer opinions were substantially similar to the mathematical model, which reflects the potential of the model as a specialist system.

The use of Artificial Intelligence methods throughout Paraconsistent Logics, allowed significant improvement in cephalometric assessment. The presented model can be applied in different samples or populations, with adaptation of the degrees of normality as initial references.

Keywords: orthodontic diagnosis, craniometrics variables, cephalometric analysis, Artificial Intelligence, Paraconsistent Logic, Paraconsistent Neural Networks.

1. INTRODUÇÃO

1.1 Análise cefalométrica

A Cefalometria é uma técnica que fraciona o complexo dento-cranio-facial, com o propósito de examinar de que forma as partes se relacionam entre si, e como os incrementos individuais de crescimento ou mudanças com tratamento afetam o conjunto (Jabarak, 1972). Ampliando este conceito, pode-se dizer ainda que, “Cefalometria é uma técnica para se resumir as complexidades anatômicas da cabeça do ser humano vivo, dentro de um esquema geométrico. O que alimenta a Cefalometria é a Biologia, sendo a sua expressão, a Geometria “ (Moyers e Bookstein, 1988).

A evolução no processo do planejamento do tratamento ortodôntico tem ocorrido de forma acelerada nos últimos anos. Antes da introdução da cefalometria radiográfica nos anos 40, a tomada de decisão para o tratamento ortodôntico era inicialmente baseada em observações sobre a forma facial e a relação entre os dentes. A classificação de maloclusão era satisfatoriamente simples, sendo o problema do paciente considerado como pertencente à classe I, II ou III de Angle¹. O ortodontista prescrevia, então, o tratamento de acordo com o movimento dentário desejado para a correção da maloclusão. Em 1930, a radiografia cefalométrica foi introduzida, e o aprimoramento desta tecnologia e sua aceitação dentro da comunidade ortodôntica foram graduais. O uso rotineiro da cefalometria e sua evolução para um padrão de cuidado não foram obtidos até as décadas de 50 e 60. Depois da radiografia cefalométrica tornar-se mais comum e melhor compreendida, os ortodontistas tornaram-se mais conscientes sobre o papel da desproporção mandibular implícita e da etiologia da maloclusão. Os métodos

¹ Angle EH (1855-1930). Pesquisador em Ortodontia, criador de vários aparelhos ortodônticos, idealizador da Ortodontia como especialidade, e fundador da “Sociedade Americana de Ortodontistas”.

de análise e tratamento, designados para direcionar os problemas dental e esquelético, tornaram-se mais amplamente propagados (Ackerman e Proffit, 1997; Sarver, 1998).

Há problemas dentários e maxilares que se apresentam sob o mesmo aspecto em comparação aos modelos de estudo e cujos diagnóstico e plano de tratamento são completamente diferentes. É precisamente nessa diferenciação que intervém a Cefalometria. Ela é estruturada em uma análise objetiva de valores mensuráveis, diferente do exame clínico, que pode ser subjetivo. Ricketts² descreveu o que seriam os quatro aspectos principais da cefalometria, chamados de “4C” (Langlade, 1993):

1. Caracterização ou descrição morfológica das condições existentes, quer sejam anatômicas, fisiológicas ou patológicas.
2. Comparação de um indivíduo com um outro ou com ele mesmo em diferentes idades (comparação longitudinal ou transversal).
3. Classificação das diversas disposições anatômicas (maxilares, alveolares, dentárias), em diferentes categorias esqueléticas, dentárias ou ambas.
4. Comunicação dos diferentes aspectos reconhecidos pelo clínico no mundo profissional, aos pais ou ao paciente.

Os traçados cefalométricos são feitos tradicionalmente em papel transparente de acetato, fixado sobre a radiografia no negatoscópio³, além do material para o traçado (lápiz, borracha, régua, compasso, transferidor, etc). Com o auxílio de cálculos

² Ricketts RM. Pesquisador em Ortodontia sobre o uso do raio X cefalométrico, introdutor da Terapia Bioprogressiva (Técnica de Ricketts). Utilizou o computador e equipe de estatísticos (métodos estatísticos biométricos) para o estudo de casos.

³ Equipamento com luz “fria”, no qual a radiografia é sobreposta, que permite visualização de detalhes da mesma.

matemáticos e com o estudo de cefalogramas e suas medidas obtidas, a Cefalometria pode ilustrar o crescimento previsível do crânio do indivíduo.

O uso da computação gráfica permitiu a visualização do efeito do tratamento sobre a face, sendo que essa tecnologia e a interação pessoal permitem ao ortodontista desenhar primeiro a face e medir o que é necessário para obter os resultados. O desenvolvimento da informática também tornou mais eficiente o processo de coleta de dados e quantificação do plano de tratamento (Ackerman e Proffit, 1997; Sarver, 1998).

1.2 Variáveis craniométricas

Ricketts mostrou que o crescimento craniano se manifesta em “raios de sol”, irradiando cada um dos pontos cefalométricos a partir de um ponto craniano central. Os diferentes pontos cefalométricos crescem de acordo com um fator relacionado à sua localização (Langlade, 1993), conforme a figura 1.1.




Figura 1.1. Sobreposição na base do crânio mostrando o crescimento em “raios de sol” entre as idades de 8 e 18 anos (Langlade, 1993).

A análise cefalométrica proposta neste trabalho mede as alterações esqueléticas anteroposteriores, verticais e alterações dentárias. Escolheram-se, para a análise, os pontos cefalométricos selecionados descritos na figura 1.2, que foram originalmente propostos pelos autores: Downs⁴, Steiner⁵, Sassouni⁶, Jacobson⁷ e Ricketts⁸.

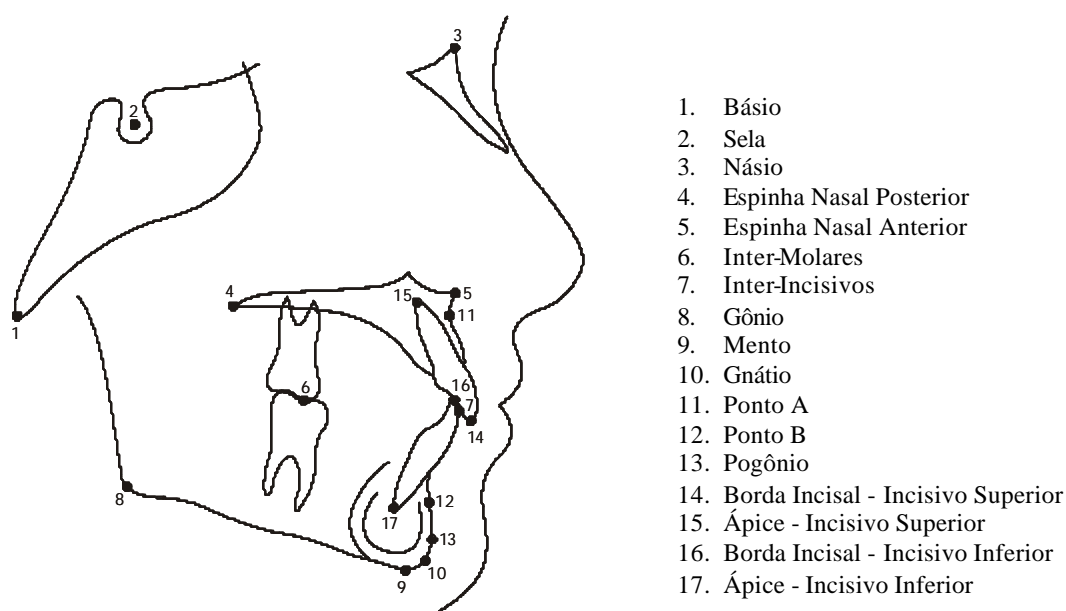


Figura 1.2. Pontos cefalométricos que serão utilizados para análise cefalométrica.

De acordo com o trabalho *An Atlas of Craniofacial Growth - Cephalometric Standards from the University School Growth Study* (Riolo, Moyers, McNamara, Hunter, 1974), foram descritas 188 variáveis craniométricas, obtidas a partir de 57

⁴ Downs WB. *Variations in facial relationships: their significance in treatment and prognosis*, 34(10); 1948.

⁵ Steiner CC. *Cephalometrics for you and me*, 729 – 55, 1953.

⁶ Sassouni V. *Diagnosis and treatment planning via roentgenographic cephalometry*, 433-63; 1958.

⁷ Jacobson A. *The “Wits” appraisal of Jaw disharmony*, 25-38; 1975.

⁸ Ricketts RM. *Cephalometric Synthesis*. Am. J. Orthod. 46: 647 – 673; 1960.

pontos cefalométricos. A tabela 1.1 traz uma breve descrição dos pontos cefalométricos utilizados para a análise cefalométrica neste trabalho:

Ponto cefalométrico	Descrição
Básio	ponto posterior na margem anterior da asa maior do osso esfenoide.
Sela	centro da fossa pituitária.
Násio	junção na sutura fronto-nasal.
Espinha nasal posterior	ponto mais posterior no plano sagital.
Espinha nasal anterior	ponto mais anterior da maxila, na região de assoalho nasal.
Inter-molares	ponto entre o extremo anterior do primeiro molar mandibular e o extremo anterior do primeiro molar maxilar.
Inter-incisivos	ponto entre o extremo incisal no incisivo central da maxila e o extremo incisal no incisivo central da mandíbula.
Gônio	ponto médio angular da mandíbula.
Mento	ponto mais inferior do contorno sinfiseal.
Gnátio	ponto mais anterior - inferior na sínfise óssea do mento.
Ponto A	ponto mais posterior na curva da maxila.
Ponto B	ponto mais posterior da linha do Infradental para o Pogônio na superfície anterior do contorno sinfiseal da mandíbula.
Pogônio	ponto mais anterior do contorno ósseo do mento.
Borda incisal – incisivo superior	extremo incisal no incisivo central da maxila.
Ápice – incisivo superior	o extremo da raiz no incisivo central da maxila.
Borda incisal – incisivo inferior	extremo incisal no incisivo central da mandíbula.
Ápice – Incisivo Inferior	o extremo da raiz no inciso central da mandíbula.

Tabela 1.1. Descrição dos pontos cefalométricos utilizados.

As discrepâncias esqueléticas anteroposteriores são avaliadas a partir das seguintes variáveis: SNA, SNB, ANB e Wits. A figura 1.3 mostra estas variáveis craniométricas:




Figura 1.3. Variáveis craniométricas para análise de discrepâncias esqueléticas anteroposteriores.

- **SNA** (°) - Sela-Násio/Ponto A (Maxila);
- **SNB** (°) - Sela-Násio/Ponto B (Mandíbula);
- **ANB** (°) - Diferença entre SNA e SNB;
- **Wits** (mm) - Projeção dos pontos A e B no Plano Oclusal.

As contribuições de Downs (Dows, 1948), especificando os limites anteriores da maxila e da mandíbula, e de Riedel (Riedel, 1948), empregando a diferença entre os ângulos SNA e SNB, iniciaram um processo de análise que teve aceitação geral, contribuindo para a obtenção de melhores resultados nos tratamentos. O ângulo ANB proposto por Riedel (Riedel, 1948) é uma medida relevante pela posição espacial do násio (Interlandi, 1999), porque determina a posição da maxila em relação à mandíbula.

A avaliação Wits, proposta por Jacobson (Jacobson, 1975), baseia-se no trabalho desenvolvido por Jenkins (Jenkins, 1955a e 1955b) e Harvold (Harvold, 1963). Esta surgiu como uma alternativa para relacionar, sagitalmente, maxila e mandíbula. Em virtude das variações espaciais do násio, Jacobson (Jacobson, 1975) empregou o plano oclusal como referência para relacionar sobre ele, a posição relativa da maxila e da mandíbula, projetando ortogonalmente os pontos A e B no plano oclusal (Interlandi, 1999).

Neste trabalho, as discrepâncias esqueléticas verticais avaliam-se a partir das variáveis: Se-Go, Na-Me, Na-ENA, SN/PP, SN/PO, SN/PM e Eixo Y. A figura 1.4 mostra estas variáveis craniométricas.

A relação percentual entre a altura anterior (násio-mento) e posterior da face (sela-gônio), permite antecipar a direção do crescimento facial (Jarabak, 1975). As medidas que envolvem os planos, assim como o eixo Y, permitem identificar uma proporcionalidade entre o crescimento vertical e horizontal.

As alterações dentárias avaliam-se nesse trabalho a partir das variáveis: U1.SN, U1.PP, U1.NA, L1.GoMe, L1.NB, L1-NB, L1.APG, L1-APG, e U1.L1. A figura 1.5 mostra estas variáveis craniométricas.

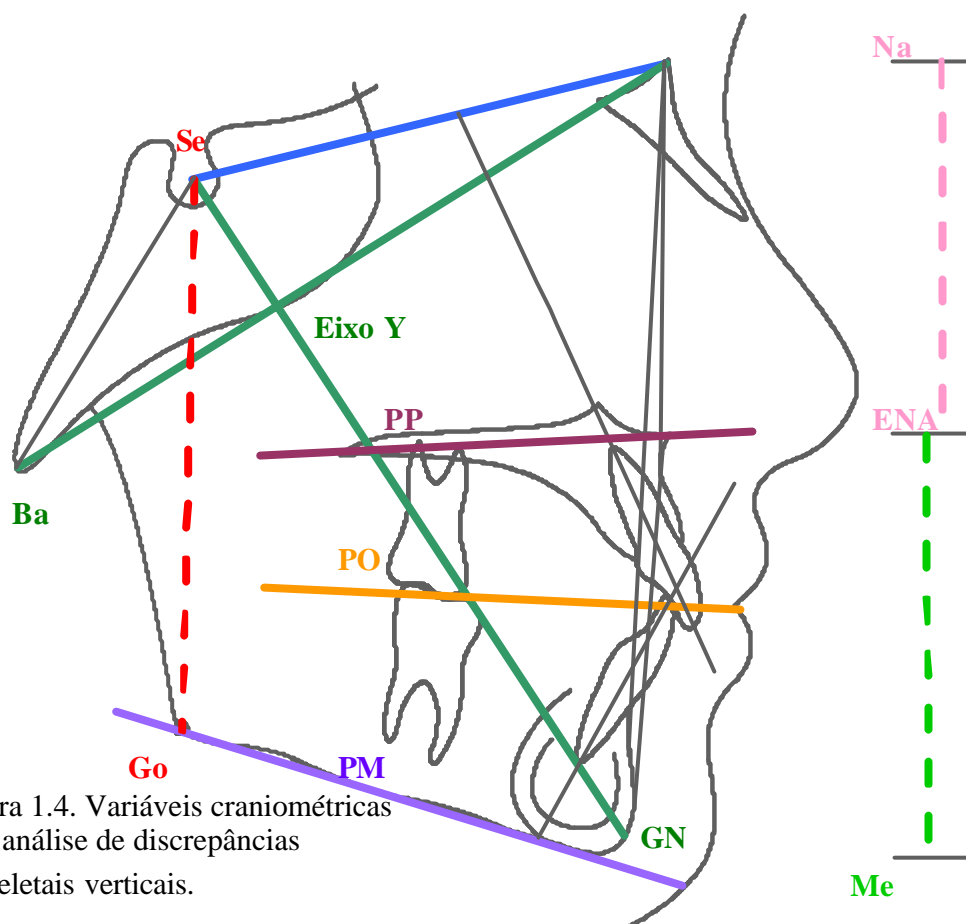


Figura 1.4. Variáveis craniométricas para análise de discrepâncias esqueléticas verticais.

- **Se-Go** (mm) - Sela-Gônio (Altura Facial Posterior);
- **Na-Me** (mm) - Násio-Mento (Altura Facial Anterior);
- **Na-ENA** (mm) - Násio-Espinha Nasal Anterior;
- **ENA-Me** (mm) - Espinha Nasal Anterior-Mento;
- **SN/PP** (°) - Sela-Násio/Plano Palatino;
- **SN/PO** (°) - Sela-Násio/Plano Oclusal;
- **SN/PM** (°) - Sela-Násio/Plano Mandibular;
- **Eixo Y** (°) - Básio-Násio/Sela-Gnátio.




Figura 1.5. Variáveis craniométricas para análise de alterações dentárias.

- **U1SN** (°) - Incisivo Superior/Sela-Násio;
- **U1PP** (°) - Incisivo Superior/Plano Palatino;
- **U1-NA** (mm) - Incisivo Superior – Násio-Ponto A;
- **L1.GoMe** (°) - Incisivo Inferior/Gônio-Mento;
- **L1.NB** (°) - Incisivo Inferior/Násio-Ponto B;
- **L1-NB** (mm) - Incisivo Inferior – Násio-Ponto B;
- **L1.APg** (°) - Incisivo Inferior/Ponto A-Pogônio;
- **L1-APg** (mm) - Incisivo Inferior – Ponto A-Pogônio;
- **U1L1** (°) - Incisivo Superior/Incisivo Inferior.

As variáveis craniométricas envolvendo os incisivos superiores e inferiores, determinam o posicionamento dos mesmos (vestibularizados ou lingualizados), enquanto que a medida do ângulo formado pelos mesmos (U1.L1), auxilia na decisão de extrações dentárias.

1.3 Análise cefalométrica e uso de técnicas de Inteligência Artificial para o diagnóstico ortodôntico

Para que a análise cefalométrica proposta nesse trabalho seja implementada, é necessário que as variáveis sob análise sejam comparadas com um padrão de referência de normalidade. Para a obtenção dos dados, utilizou-se como referência o *Atlas de Crescimento Craniofacial* (Martins et al., 1998), que dispõe de dados de jovens brasileiros predominantemente descendentes de países do Mediterrâneo, na faixa etária entre 6 e 18 anos. Pela dificuldade de acesso, outras fontes de dados sobre variáveis craniométricas não foram consideradas nesse trabalho. Contudo, a técnica aplicada permite que seja utilizada para indivíduos de outros grupos étnicos, bastando mudar as referências para o grupo étnico do qual se disponha dos dados e ajustar a Rede Neural Artificial Paraconsistente (Da Silva Filho e Abe, 2001).

A análise cefalométrica pode ser mais precisa em função do uso de medidas transversais do crânio, porém, não há trabalhos disponíveis na literatura seguindo a mesma metodologia de coleta de dados empregada para as variáveis obtidas da radiografia lateral, e por esse motivo, também não foram consideradas.

Para um diagnóstico ortodôntico, as variáveis craniométricas devem ser tratadas de forma contextualizada, ou seja, os resultados da quantificação das variáveis são

passíveis de interação para que possa ser gerado um parecer a respeito de alguma disfunção. Neste trabalho, são utilizadas técnicas de Inteligência Artificial, aplicando-se os fundamentos da Lógica Paraconsistente Anotada, para parametrizar e contextualizar tais variáveis craniométricas, o que potencialmente amplia o uso clínico das informações providas pelas análises e possibilita um diagnóstico em ortodontia.

Técnicas de Inteligência Artificial têm sido utilizadas para auxiliar na modelagem e/ou implementação de inúmeros sistemas especialistas, e a tendência é que esses sistemas possam cada vez mais ser utilizados na área médica. Como exemplos em ortodontia podem-se citar trabalhos como *The validation of an expert system rule-base for fixed appliance treatment planning* (Stephens e Mackin, 1998), que retrata um sistema especialista para planejamento de tratamento, *An inference modeling of human visual judgement of sagittal jaw-base relationships based on cephalometry: Part I* (Takada, Sorihashi, Stephens e Itoh, 2000), *An inference modeling of human visual judgement of sagittal jaw-base relationships based on cephalometry: Part II* (Sorihashi, Stephens e Takada, 2000), e *Fuzzy modelling for selecting headgear types* (Akçam e Takada, 2002) que aplicam sistemas de regras *fuzzy* e se utilizam da cefalometria para avaliar discrepâncias.

1.4 Inteligência Artificial

A Inteligência Artificial (IA) é uma área de pesquisa, dentro das ciências exatas, razoavelmente recente, seja nos seus aspectos teóricos ou aplicados. Alguns de seus conceitos começaram a ser discutidos após a Segunda Guerra Mundial, e em 1956,

durante um seminário organizado por John McCarthy⁹ no Dartmouth College, Princeton, EUA, foi adotado o termo IA para o campo da ciência que trata de construir máquinas que funcionem de forma autônoma em ambientes complexos e mutáveis (Russell e Norvig, 2004). As atividades realizadas por essas máquinas podem envolver a sensopercepção (como tato, audição e visão), as capacidades intelectuais (como aprendizado de juízos, raciocínio dedutivo e memória), a linguagem (como as verbais e gráficas) e atenção (decisão no sentido de concentrar as atividades sobre um determinado estímulo).

As pesquisas em IA se estendem no campo da Linguagem Natural, das Redes Neurais Artificiais, da Lógica, da Robótica e outras subáreas da IA. Assim, IA é, em parte, o estudo do próprio Homem e a sua relação com o meio que o cerca (Nascimento Jr. e Yoneyama, 2000).

Naturalmente, uma definição adequada de IA é difícil ou mesmo impossível, entretanto, para os propósitos deste trabalho, uma aproximação adequada é: “IA é o campo de conhecimentos onde se estudam sistemas capazes de reproduzir algumas das atividades mentais humanas” (Nilsson, 1986).

Alguns segmentos da ciência como a Filosofia, a Matemática, a Economia, a Neurociência, a Psicologia, a Lingüística, a Engenharia de Computadores, a Teoria de Controle e a Cibernética, contribuíram com idéias, conceitos e técnicas para o desenvolvimento teórico e prático da IA (Russell e Norvig, 2004).

⁹ John McCarthy criou a linguagem Lisp, utilizada em IA, e foi um dos criadores do conceito de compartilhamento de tempo (*time sharing*), utilizado em computação.

Atualmente, a IA vem sendo utilizada em muitas atividades, onde a seguir destacam-se alguns exemplos:

- O programa *Remote Agent* da Nasa se tornou o primeiro programa de planejamento autônomo de bordo a controlar o escalonamento de operações de uma nave espacial. O *Remote Agent* gerou planos de metas de alto nível especificadas a partir do solo e monitorou a operação de uma nave espacial à medida que os planos eram executados, efetuando a detecção, o diagnóstico e a recuperação de problemas conforme eles ocorriam (Russell e Norvig, 2004).
- O programa *Deep Blue* da IBM se tornou o primeiro programa de computador a derrotar um campeão mundial (Garry Kasparov) em uma partida de xadrez (Russell e Norvig, 2004).
- O sistema de visão de computador *ALVINN* foi treinado para dirigir um automóvel, mantendo-o na pista, caracterizando um controle autônomo. Ele foi colocado em uma minivan controlada por um computador *NAVLAB da CMU* e foi utilizado para percorrer os Estados Unidos, mantendo o controle da direção do veículo durante 98% do tempo, em um percurso de 4600km. A *NAVLAB* tem câmeras de vídeo que transmitem imagens da estrada para *ALVINN*, que então calcula a melhor forma de guiar, baseado na experiência obtida em sessões de treinamento anteriores (Russell e Norvig, 2004).
- Durante a crise do Golfo Pérsico em 1991, as forças armadas dos Estados Unidos utilizaram uma ferramenta denominada de *Dynamic*

Analysis and Replanning Tool (DART), a fim de realizar o planejamento logístico automatizado e a programação de execução de transporte. Isso envolveu até 50000 veículos, transporte de carga aérea e pessoal ao mesmo tempo, e teve de levar em conta pontos de partida, destinos, rotas e resolução de conflitos entre todos os parâmetros. As técnicas de planejamento da IA permitiram a geração, em algumas horas, de um plano que exigiria semanas com outros métodos. A Defense Advanced Research Project Agency (DARPA) declarou que essa única aplicação compensou com folga os 30 anos de investimento da DARPA em IA (Russell e Norvig, 2004).

- O uso da robótica vem sendo ampliado na área cirúrgica e muitos cirurgiões utilizam robôs assistentes em microcirurgias. Um exemplo é o *HipNav*, sistema que emprega técnicas de visão computacional para criar um modelo tridimensional da anatomia interna de um paciente, e depois utiliza controle robótico para orientar a inserção de uma prótese de substituição do quadril (Russell e Norvig, 2004).
- Programas de diagnóstico médico baseados na análise probabilística, foram capazes de executar tarefas no nível de um médico especialista em diversas áreas da medicina. Heckermann (1991) descreve um caso em que um importante especialista em patologia dos gânglios linfáticos ridiculariza o diagnóstico de um programa em um caso especialmente difícil. Os criadores do programa sugeriram que ele pedisse ao computador uma explicação do diagnóstico. A máquina destacou os

principais fatores que influenciaram sua decisão e explicou a interação sutil de vários sintomas nesse caso. Mais tarde, o especialista concordou com o programa (Russell e Norvig, 2004).

1.5 Resumo histórico das Redes Neurais Artificiais

Uma das áreas de IA que tem recebido especial atenção de especialistas é a teoria das Redes Neurais Artificiais (RNAs). As RNAs são modelos matemáticos que se assemelham às estruturas neurais biológicas e que têm capacidade computacional adquirida por meio de aprendizado e generalização (Braga et al., 2000; Haykin, 1994).

O primeiro trabalho reconhecido como um processo de IA foi realizado por Warren McCulloch e Walter Pitts (McCulloch e Pitts, 1943) e está relacionado com as RNAs. McCulloch e Pitts basearam-se em três fontes: o conhecimento da fisiologia básica e da função dos neurônios do cérebro, uma análise formal da lógica proposicional¹⁰, e a teoria da computação de Turing¹¹ (Turing, 1950). Os dois pesquisadores propuseram um modelo de neurônios artificiais que se caracterizavam por estarem ativados ou não, e ainda poderem ser estimulados por neurônios vizinhos (Russell e Norvig, 2004). A interconexão desses neurônios artificiais formava o que se denomina uma Rede Neural Artificial. Eles demonstraram que qualquer função computável podia ser calculada por este tipo de rede, e que todos os conectivos lógicos usuais (“e”, “ou”, “não”, etc.) podiam ser implementados por estruturas de redes

¹⁰ A lógica proposicional juntamente com o estudo do cálculo de predicados formam a parte nuclear da Lógica Clássica.

¹¹ Alan Turing (1950) projetou o “*Teste de Turing*” para fornecer uma definição operacional satisfatória de “inteligência”.

simples. McCulloch e Pitts também sugeriram que as redes, se definidas adequadamente, seriam capazes de “aprender”. Donald Hebb (1949) demonstrou uma regra de atualização simples para modificar as intensidades de conexões entre os neurônios. Essa regra chamou-se “Aprendizagem de Hebb” e é um dos modelos usados atualmente.

Em 1950, Alan Turing articulou uma visão completa de IA em um artigo intitulado *Computing Machinery and Intelligency* (Turing, 1950), onde ele apresentou o teste de Turing, aprendizagem de máquina, algoritmos genéticos e aprendizagem por reforço.

Em 1958, John McCarthy, em um artigo intitulado *Programs with common sense* (McCarthy, 1958), descreveu um programa hipotético, o *Advice Taker*, que procura incorporar o conhecimento geral do mundo. O programa pode aceitar novos axiomas no curso normal de operação, além daqueles previamente programados, permitindo que ele adquira competências em novas áreas sem ser reprogramado. Portanto, o *Advice Taker* incorporava os princípios centrais de representação do conhecimento e de raciocínio da época.

Vários trabalhos promoveram o avanço das Redes Neurais Artificiais. O trabalho de Winograd e Cowan (Winograd e Cowan, 1963) mostrou que um grande número de elementos podia representar coletivamente um conceito individual, com um aumento correspondente na robustez e no paralelismo. Os métodos de aprendizado de Hebb foram aperfeiçoados por Bernie Widrow, com o desenvolvimento das redes *Adalines*, e por Frank Rosenblatt (Rosenblatt, 1962) com o desenvolvimento dos Perceptrons.

1.6 Características das Redes Neurais Artificiais

Uma rede neural artificial, vista como uma máquina adaptativa, pode ser definida como um processador paralelamente distribuído, constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso (Haykin, 2001).

O aprendizado e a generalização também constituem características importantes das RNAs. O aprendizado está normalmente associado à capacidade de as mesmas adaptarem os seus parâmetros como consequência da sua interação com o meio externo. O processo de aprendizado é interativo e por meio dele a RNA deve melhorar o seu desempenho gradativamente à medida que interage com o meio externo. O critério de desempenho que determina a qualidade do modelo neural e o ponto de parada de treinamento são preestabelecidos pelos parâmetros de treinamento. A generalização de uma RNA está associada à sua capacidade de dar respostas coerentes para dados não apresentados a ela previamente durante o treinamento. Esta característica foi considerada, durante algum tempo, como sendo inerente e resultante do processo de treinamento. Esperava-se que uma RNA treinada tivesse uma boa capacidade de generalização independentemente de ter sido controlada durante o treinamento. No entanto, atualmente os fatores que afetam a generalização são mais conhecidos e boa parte das pesquisas atuais, na área, visam ao desenvolvimento de modelos e técnicas de aprendizado que tenham algum controle de generalização. O conceito atual é que aprendizado e generalização andam juntos em vez de que a generalização surge naturalmente como consequência do aprendizado (Rezende, 2003).

Uma rede neural artificial se “assemelha” ao cérebro em alguns aspectos por essas características:

- O conhecimento é adquirido pela rede a partir de seu ambiente, através de um processo de aprendizagem;
- Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido (Haykin, 2001).

O esboço de um neurônio biológico é mostrado na figura 1.6 e, comparativamente, o modelo não-linear de um neurônio artificial é mostrado na figura 1.7.

Um neurônio faz conexões com 10 a 100000 outros neurônios, em junções chamadas sinapses. Os sinais se propagam de um neurônio para outro por meio de uma reação eletroquímica. Os sinais controlam a atividade cerebral em curto prazo, e também permitem mudanças a longo prazo na posição e na conectividade dos neurônios. Acredita-se que esses mecanismos formem a base para o aprendizado no cérebro (Russell e Norvig, 2004).




Figura 1.6. Esquemático simplificado de partes de uma célula nervosa ou neurônio.

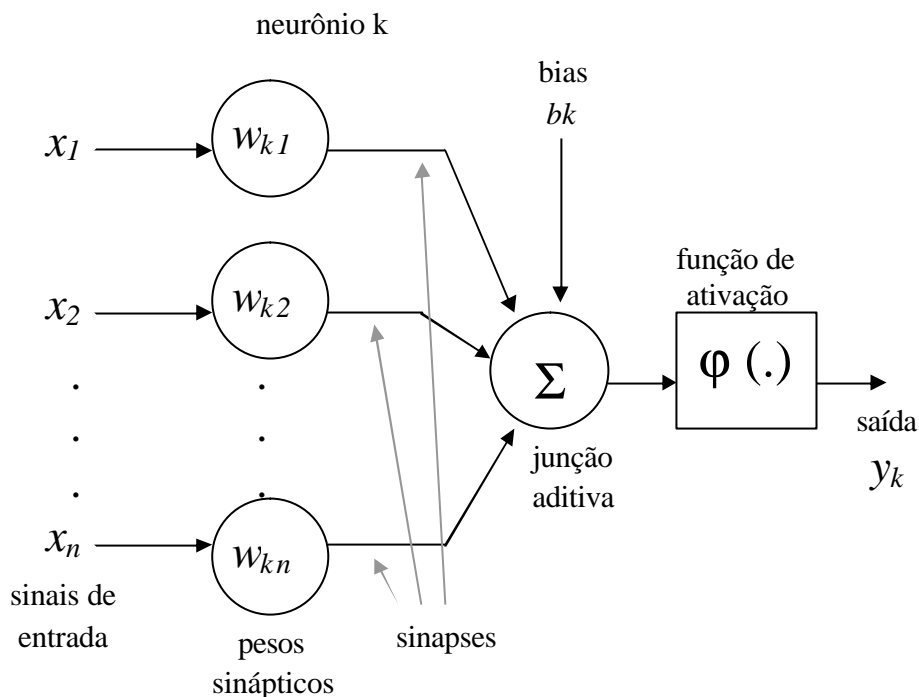


Figura 1.7. Modelo de um neurônio artificial típico.

O modelo típico de neurônio artificial apresentado na figura 1.7 forma a base para o desenvolvimento de redes neurais artificiais. O modelo é formado por um conjunto de sinapses, afetadas por um peso. Um sinal x_j aplicado na entrada da sinapse j conectada ao neurônio k é multiplicada pelo peso sináptico w_{kj} , onde o primeiro índice (k) se refere ao neurônio em questão e o segundo (j) se refere ao terminal de entrada da sinapse, a qual o peso se refere. O peso sináptico de um neurônio artificial pode estar em um intervalo que inclui valores positivos e negativos.

A junção aditiva soma os sinais de entrada, ponderados pelas respectivas sinapses do neurônio artificial. A função de ativação limita a amplitude da saída de um neurônio. O intervalo normalizado da amplitude de saída de um neurônio está entre $[0, 1]$ ou $[-1, 1]$.

O *bias* ou ajuste aplicado externamente produz o efeito de aumentar ou diminuir a entrada da função de ativação (Haykin, 2001).

1.7 Sistemas Especialistas

Sistemas Especialistas atuam como consultores qualificados em uma determinada área do conhecimento. De acordo com a área de atuação, devem fornecer diagnósticos, condutas, sugestões ou outras informações pertinentes, obtidas a partir de dados fornecidos e de conhecimentos armazenados previamente. Os Sistemas Especialistas permitem que conhecimentos possam ser disseminados e utilizados sem a necessidade da presença do especialista. Além disso, eles permitem que conhecimentos de vários especialistas possam ser concentrados em uma única base de dados (Nascimento Jr. e Yoneyama, 2000). Algumas técnicas utilizadas pelos Sistemas Especialistas, que podem ser aplicadas isoladamente ou em conjunto para auxiliar o processo decisório são: Aquisição de Conhecimento, Aprendizado de Máquina, Redes Neurais, Lógica Fuzzy, Computação Evolutiva, Agentes e Multiagentes, Mineração de Dados e de Textos (Rezende, 2003).

O programa DENDRAL (Buchanan et al., 1969), utiliza a aquisição de conhecimento específico para resolver o problema de inferir a estrutura molecular a partir das informações fornecidas por um espectômetro de massa. A entrada para o processo consiste na fórmula elementar da molécula e o espectro de massa que fornece as massas dos diversos fragmentos da molécula gerada quando ela é bombardeada por um feixe de elétrons. O DENDRAL representou o primeiro sistema bem sucedido de conhecimento intensivo, cuja habilidade derivava de um grande número de regras de

propósito específico. Foi o primeiro programa a incorporar o conceito de Sistema Especialista.

A metodologia de Sistema Especialista foi dedicada em seguida, à área do diagnóstico médico. Os Doutores Feigenbaum, Buchanan e Edward Shortliffe (Buchanan e Shortliffe, 1984) desenvolveram o programa MYCIN para diagnosticar infecções sangüíneas. Com cerca de 450 critérios (regras), o MYCIN foi capaz de se sair tão bem quanto alguns especialistas, e melhor do que médicos em início de carreira. O MYCIN apresentava duas diferenças importantes em relação ao DENDRAL. Primeiro, diferentemente das regras do DENDRAL, não havia nenhum modelo teórico geral a partir do qual as regras do MYCIN pudessem ser deduzidas. Elas tinham de ser adquiridas a partir de entrevistas extensivas com especialistas que, por sua vez, as adquiriam de livros didáticos, de outros especialistas e da experiência direta de estudos de casos. Segundo, as regras tinham de refletir a incerteza associada ao conhecimento médico. O MYCIN incorporava um cálculo de incerteza chamado de fatores de certeza que se adequavam bem a forma como os médicos avaliavam o impacto das evidências do diagnóstico (Russell e Norvig, 2004).

Portanto, pode-se concluir que Sistemas Especialistas são sistemas baseados em conhecimento que resolvem problemas ordinariamente resolvidos também por um especialista humano. Por isso, eles requerem conhecimento sobre a habilidade, a experiência e as heurísticas usadas pelo especialista. Além disso, seu processo de desenvolvimento envolve uma profunda interação com o especialista (Rezende, 2003).

A realização deste trabalho foi possível graças a união de técnicas implementadas pelas Redes Neurais Artificiais e pelos Sistemas Especialistas.

1.8 Inteligência Artificial e Redes Neurais Artificiais na atualidade

Os estudos das Redes Neurais Artificiais ganharam força a partir da década de 80. Físicos como John Hopfield (Hopfield, 1982) usaram técnicas da mecânica estatística para analisar as propriedades de armazenamento e de otimização das redes, tratando coleções de nós de rede como coleções de átomos.

A partir da segunda metade da década de 1980, pelo menos quatro grupos diferentes recriaram o algoritmo de aprendizado por retropropagação para as redes neurais, iniciado em 1969. O algoritmo foi aplicado a muitos problemas de aprendizagem em Ciência da Computação e Psicologia, e foi feita ampla disseminação dos resultados na coletânea *Parallel Distributed Processing* (Rumelhart e McClelland, 1986). São os chamados modelos conexionistas.

Os modelos conexionistas para sistemas inteligentes eram vistos, por alguns, como concorrentes diretos dos modelos simbólicos promovidos por Newell e Simon¹² e do tratamento logicista de McCarthy e outros pesquisadores (Smolensky, 1988). Pode parecer óbvio que, em certo nível, os seres humanos manipulem símbolos, mas os conexionistas questionam se a manipulação de símbolos tem qualquer função explicativa real em modelos detalhados de cognição. A visão atual é a de que os estudos conexionista e simbólico são complementares e não concorrentes (Russell e Norvig, 2004).

¹² Allen Newell e Herbert Simon desenvolveram em 1961 o “General Problem Solver”, com a preocupação em comparar os passos de suas etapas de raciocínio aos passos de sujeitos humanos resolvendo os mesmos problemas (modelagem cognitiva).

A obra *Probabilistic Reasoning in Intelligent Systems*, de Judea Pearl (Pearl, 1988), levou a uma nova aceitação da teoria de probabilidade e da teoria da decisão na IA. O formalismo denominado *rede bayesiana* foi criado para permitir a representação eficiente do conhecimento incerto e o raciocínio rigoroso. Esse estudo supera muitos problemas dos sistemas de raciocínio probabilístico das décadas de 1960 e 1970, e atualmente ele domina a pesquisa de IA sobre raciocínio incerto e sistemas especialistas. A abordagem admite o aprendizado a partir de experiência e combina o melhor da IA clássica e das Redes Neurais (Russell e Norvig, 2004).

1.9 Lógica Paraconsistente

A Lógica Paraconsistente¹³ surgiu dos trabalhos formalizados por volta de 1948 de forma independente, pelo polonês Stanislaw Jaskowski e pelo brasileiro Newton C. A. Da Costa¹⁴, embora houvessem precursores como N. Vasiliev e J. Tukasiewicz. A Lógica Paraconsistente se destaca por infringir o princípio da não-contradição.

Diz-se que uma teoria dedutiva é *consistente* se não possuir teoremas contraditórios, um dos quais é a negação do outro. Caso contrário, a teoria diz-se *inconsistente* (ou *contraditória*). Uma teoria é chamada *trivial* se todas as fórmulas (ou sentenças) de sua linguagem forem nela demonstráveis; em hipótese contrária, diz-se *não-trivial* (Da Costa e Abe, 2001).

¹³ Termo cunhado pelo filósofo peruano Francisco Miró Quesada, em 1976.

¹⁴ Os cientistas S. Jaskowski e Newton C. A. da Costa são considerados pela comunidade científica como os inventores da Lógica Paraconsistente

Analogamente, a definição aplica-se a sistemas de proposições, sistemas de informações etc, (levando-se em conta, o conjunto das conseqüências dos mesmos).

Se a lógica subjacente a uma teoria T é a lógica clássica ou alguma de suas extensões, então T é inconsistente, se e somente se for trivial. Portanto, para elaborar teorias ou sistemas de informação inconsistentes, mas, não-triviais, deve-se recorrer a um tipo novo de lógica.

A Lógica Paraconsistente é uma lógica que pode servir de base para teorias inconsistentes e não-triviais.

Uma lógica é chamada paracompleta se pode funcionar como a lógica subjacente de teorias na qual há fórmulas tais que estas fórmulas e suas negações são ambas falsas. Uma teoria é chamada paracompleta se sua lógica subjacente é uma lógica paracompleta. Como conseqüência, teorias paraconsistentes não satisfazem o princípio da não-contradição que pode ser expressa como segue: “de duas proposições contraditórias (i.e., uma delas é negação da outra) uma deve ser falsa” .

Além disso, teorias paracompletas não satisfazem o princípio do terceiro excluído, formulado como se segue: “de duas proposições contraditórias, uma deve ser verdadeira”.

Finalmente, lógicas que são simultaneamente paraconsistentes e paracompletas chamam-se lógicas *não-aléticas* (Da Silva Filho e Abe, 2001a).

Em algumas situações, quando se necessita efetuar descrições mais próximas da realidade, a lógica clássica se mostra ineficaz ou mesmo impossibilitada de ser aplicada. Alguns trabalhos, de cunho estritamente teórico, já sugeriram a Lógica Paraconsistente

como uma boa solução para o tratamento do conhecimento incerto inerentes a estas situações reais (Abe, Akama e Da Silva Filho, 2000).

Os resultados de alguns trabalhos relevantes, expostos na literatura especializada, mostram a possibilidade de aplicações diretas da Lógica Paraconsistente Anotada (item 1.9.1), que constitui um tipo de Lógica Paraconsistente, na área de Inteligência Artificial. Nesses trabalhos são encontradas pesquisas promissoras sobre a construção de sistemas de controle e de programas aplicativos de simulação. Entre os trabalhos publicados, destaca-se o algoritmo *Para-analisador* (Da Silva Filho, 1999) onde métodos computacionais de análises paraconsistentes podem ser projetados através do algoritmo da Lógica Paraconsistente Anotada.

Os estudos posteriores apresentados em trabalhos que tratam de sistemas computacionais, permitem afirmar que o algoritmo pode ser implementado por *software*, como programa aplicativo e desenvolvido utilizando linguagem de computação convencional, proporcionando a aplicação da Lógica Paraconsistente em sistemas de controle e Sistemas Especialistas de Inteligência Artificial.

1.9.1 Lógica Paraconsistente Anotada

As Lógicas Paraconsistentes Anotadas são uma família de lógicas não-clássicas inicialmente empregadas em programação lógica por Subrahmanian (Subrahmanian, 1987).

Devido às aplicações obtidas, tornou-se conveniente um estudo dos fundamentos da lógica subjacente das linguagens de programação investigadas. Verificou-se que se

tratava de uma Lógica Paraconsistente e que, em alguns casos, também continham características da lógica para completa e não-alética.

Os primeiros estudos sobre os fundamentos da Lógica Paraconsistente Anotada foram efetuados por Da Costa, Vago e Subrahmanian (Da Costa, Vago e Subrahmanian, 1991), por Da Costa, Abe e Subrahmanian (Da Costa, Abe e Subrahmanian, 1991) e Abe (Abe, 1992).

Em (Abe, 1992) estudou-se a lógica de predicados, teoria de modelos, teoria anotada de conjuntos e alguns sistemas modais¹⁵, estabelecendo-se um estudo sistemático dos fundamentos das lógicas anotadas apontadas em trabalhos anteriores. Em particular, obteve-se metateoremas¹⁶ de completeza forte e fraca para uma subclasse de lógica anotada de primeira ordem e fez-se um estudo sistemático da teoria anotada de modelos, generalizando a maioria dos resultados padrão para os sistemas anotados.

Outras aplicações dos sistemas anotados foram iniciados por Abe por volta de 1993 e, juntamente com discípulos diretos, implementou-se a linguagem de programação paraconsistente *Paralog* (Abe, 1997; Abe e Da Silva Filho, 1996) independentemente dos resultados obtidos por Subrahmanian (Subrahmanian, 1987).

Tais idéias aplicaram-se na construção de um protótipo e especificação de uma arquitetura baseada na Lógica Paraconsistente Anotada que integra vários sistemas computacionais – planejadores, base de dados, sistemas de visão, etc. de uma célula de

¹⁵ Sistemas modais são um tipo de lógica não-clássica que estudam os operadores modais: “necessidade”, “permissão”, “impossibilidade” e “contingência”.

¹⁶ Metateorema significa um teorema sobre a Lógica Paraconsistente obtido fora da teoria. Prova-se fora da teoria que a lógica é correta e completa.

manufatura (Prado, 1996) e representação de conhecimento por Frames¹⁷, permitindo representar inconsistências e exceções (Ávila, 1996).

Da Silva Filho, outro discípulo de Abe, interessou-se na aplicação da Lógica Paraconsistente Anotada, $P\tau$, em circuitos digitais, obtendo-se a implementação das portas lógicas “Complemento”, “E” e “Ou”¹⁸ (Da Silva Filho, 1996; Abe e Da Silva Filho, 1996; Da Silva Filho e Abe, 1999a). Tais circuitos permitem sinais “conflitantes” implementados em sua estrutura de modo não-trivial. Acredita-se que a contribuição dos circuitos elétricos paraconsistentes seja pioneira na área dos circuitos elétricos, abrindo-se novas vias de investigações. Nas pesquisas referentes ainda a parte de *hardware*, uma contribuição importante foi a edificação do analisador lógico, *Para-analisador*, que permite tratar conceitos de incerteza, inconsistência e paracompleteza. Também foram construídos controladores lógicos, baseados nas lógicas anotadas, denominados PARACONTROL, como também simuladores lógicos, denominados PARASIM, e estruturas para tratamento de sinais, PARASÔNICO (Da Silva Filho e Abe, 2001b). Como materialização dos conceitos discutidos, construiu-se o primeiro robô paraconsistente com o *hardware* paraconsistente: a robô *Emmy* (Da Silva Filho, 1999; Abe e Da Silva Filho, 1996) e o protótipo II da *Emmy* foi estudado em (Torres, 2004). Um outro robô paraconsistente, construído com o *software* baseado na Lógica Paraconsistente Anotada, denominou-se *Sofya* e muitos protótipos subseqüentes foram construídos, como exemplo *Amanda*, etc.

¹⁷ Teoria de representação de conhecimento, feita a partir uma linguagem de programação clássica. Basicamente utiliza conceitos definidos ou caracterizados por herança.

¹⁸ Os conceitos relacionados às portas lógicas “Complemento”, “E” e “Ou” são originados na Teoria de Conjuntos, e estão relacionados respectivamente a negação, intersecção e união.

Os sistemas anotados também abarcam aspectos dos conceitos envolvidos em raciocínio não-monotônico¹⁹ (Nakamatsu, Abe e Suzuki, 1999).

Versões de lógicas anotadas também envolvem muitos aspectos da Lógica *Fuzzy*. Isto pode ser visto sob vários ângulos. A teoria notada de conjuntos engloba *in totum* a teoria de conjuntos *fuzzy* (Da Costa, Abe e Subrahmanian, 1991; Abe, 1992).

Versões axiomatizadas da teoria *fuzzy* foram obtidas em (Akama e Abe, 1998).

Foi erigido o controlador híbrido *parafuzzy* que une características das lógicas anotadas e fuzzy (Da Silva Filho e Abe, 1999a; Da Silva Filho e Abe, 1999b).

Finalmente, aspectos algébricos também foram investigados por Abe em (Abe, 1997) e outras algebrizações interessantes tem sido estudadas por vários autores como em (Blok e Pigozzi, 1989).

A seguir são formalizados alguns conceitos da Lógica Proposicional Paraconsistente Anotada, $P\tau$:

Seja um reticulado finito, denominado reticulado de valores verdade, $\tau = \{T, V, F, \perp\}$, onde intuitivamente, as constantes anotacionais do reticulado de 4 anotações representam:

T = inconsistente

F = falso

V = verdadeiro

\perp = paracompleto

¹⁹ É um raciocínio em que quanto mais hipóteses forem adicionadas, menos conclusão tira-se.

No contexto da Lógica Paraconsistente Anotada o termo “inconsistente” reflete a idéia de informações conflitantes, enquanto o termo “paracompleto” reflete a falta de informações.

Este reticulado é chamado de reticulado de “Quatro” representado pelo diagrama de Hasse onde as constantes de anotação são alocadas nos vértices, conforme a figura 1.8:




Figura 1.8. Reticulado de “Quatro”.

O operador negação sobre τ é $\sim : |\tau| \rightarrow |\tau|$, que define-se como:

$$\sim (V) = F$$

$$\sim (F) = V$$

$$\sim (T) = T$$

$$\sim (\perp) = \perp$$

Entre várias leituras, p_x pode ser entendida como “creio na proposição p com grau de crença ou de evidência até x ”.

De acordo com o que foi exposto, as variáveis proposicionais virão acompanhadas por constantes de anotação, que darão uma leitura intuitiva de “verdade”, de “falsidade”, de “inconsistência” ou de “paracompleteza” à proposição. Assim:

p_T = a anotação atribui uma interpretação intuitiva de inconsistente à proposição p .

$p_V =$ a anotação atribui uma interpretação intuitiva de verdade à proposição p .

$p_F =$ a anotação atribui uma interpretação intuitiva de falsidade à proposição p .

$p_{\perp} =$ a anotação atribui uma interpretação intuitiva de paracompleteza à proposição p .

No exemplo, considerou-se um reticulado com quatro anotações. No entanto, pode-se considerar reticulados com mais partições definidas de acordo com a aplicação.

1.9.2 Lógica Paraconsistente Anotada de anotação com dois valores

No restante deste capítulo será feita uma explanação da Lógica Paraconsistente Anotada de anotação com dois valores (LPA2v), do algoritmo *Para-analisador*, bem como das Redes Neurais Artificiais Paraconsistentes (RNAPs) baseada na tese de doutorado do pesquisador Jair Minoru Abe (Abe, 1992) e no livro *Redes Neurais Artificiais Paraconsistentes* (Da Silva Filho e Abe, 2001a). Na LPA2v, para cada proposição associam-se dois valores de evidência. O primeiro valor contido na anotação representa a evidência favorável à proposição p (evidência favorável - μ), e o segundo valor da anotação representa a evidência contrária à proposição p (evidência contrária - λ).

O reticulado considerado é:

$$\tau = \{ (\mu, \lambda) \mid \mu, \lambda \in [0, 1] \subset \mathfrak{R} \}, \quad (1.1)$$

onde \mathfrak{R} é o conjunto dos reais.

O operador negação $\sim : \tau \rightarrow \tau$ é definido como: $\sim [(\mu, \lambda)] = (\lambda, \mu)$. O reticulado pode ser representado como na figura 1.9




Figura 1.9. Reticulado LPA2v.

Pode-se relacionar os estados lógicos extremos representados nos quatro vértices do reticulado com os valores dos graus de evidência favorável e contrária:

$p_T = p_{(1,1)}$: a anotação atribuí à proposição p uma leitura intuitiva que p é inconsistente.

$p_V = p_{(1,0)}$: a anotação atribuí à proposição p uma leitura intuitiva que p é verdadeiro.

$p_F = p_{(0,1)}$: a anotação atribuí à proposição p uma leitura intuitiva que p é falso.

$p_{\perp} = p_{(0,0)}$: a anotação atribuí à proposição p uma leitura intuitiva que p é paracompleto.

Os graus de evidência favorável μ e contrária λ podem assumir quaisquer valores intermediários entre 0 e 1.

1.9.3 Análise da Lógica Paraconsistente Anotada de anotação com dois valores

Como será visto adiante, o reticulado LPA2v será subdividido em regiões que comporão os estados de decisão.

Assim, em uma aplicação, ao receber uma informação (constante de anotação μ ou λ), onde μ é a evidência favorável e λ é a evidência contrária, será efetuado um cálculo através de um algoritmo e este fornecerá um resultado que será o estado lógico de saída.

Na prática, os graus de evidência favorável e contrária são considerados como informações de entrada do sistema e os estados lógicos representados nos vértices e nas regiões internas do reticulado são as saídas resultantes da análise paraconsistente. O que foi discutido acima é esquematizado conforme a figura 1.10:

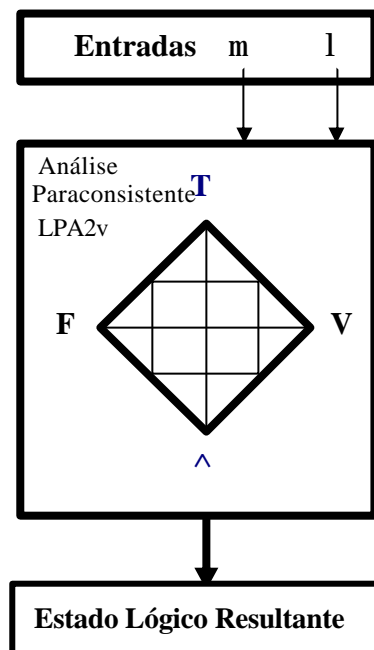


Figura 1.10. Representação da análise paraconsistente LPA2v.

1.9.4 Representação do quadrado unitário no plano cartesiano

O reticulado associado à lógica LPA2v pode ser representado no sistema cartesiano tradicional. Esta representação é denominada Quadrado Unitário no Plano Cartesiano (QUPC), e está ilustrada na figura 1.11 (Da Silva Filho e Abe, 1998):




Figura 1.11. Quadrado Unitário no Plano Cartesiano (QUPC).

Para manipular convenientemente a evidência favorável μ e a evidência contrária λ , introduz-se os conceitos de grau de certeza (Gce) e grau de contradição (Gct):

a) Grau de Contradição (Gct):

$$Gct(\mu, \lambda) = \mu + \lambda - 1, \text{ desde que } 0 \leq (\mu, \lambda) \leq 1 \quad (1.2)$$

No quadrado unitário do plano cartesiano da figura 1.11 vê-se que $Gct(\mu, \lambda) = -1$, no ponto $\hat{=} = (0, 0)$, representa uma contradição máxima negativa e que $Gct(\mu, \lambda) = +1$, onde $T = (1, 1)$, representa uma contradição máxima positiva. Quanto mais a interpolação entre os graus de evidência favorável e contrária estiver próxima à reta FV,

mais o resultado $\mu + \lambda$ se aproxima de 1, diminuindo o valor de G_{ct} , o que representa uma menor contradição entre as informações de entrada.

b) Grau de Certeza (Gce):

$$G_{ce}(\mu, \lambda) = \mu - \lambda, \text{ desde que } 0 \leq (\mu, \lambda) \leq 1 \quad (1.3)$$

Quando $G_{ce}(\mu, \lambda) = -1$, no ponto $F = (0, 1)$, significa que tem-se uma certeza máxima da negação da proposição. Para $G_{ce}(\mu, \lambda) = +1$, no ponto $V = (1, 0)$, significa que tem-se uma certeza máxima da afirmação da proposição. Quanto mais a interpolação entre os graus de crença e descrença estiver próxima à reta $\perp T$, mais o resultado $\mu - \lambda$ se aproxima de 0, diminuindo o valor de G_c , o que representa uma menor certeza entre as informações de entrada.

O reticulado passará a ser delimitado conforme a adição dos conceitos abaixo (valores entre +1 e -1):

V_{icc} : valor inferior de controle de certeza;

V_{sc} : valor superior de controle de certeza;

V_{scct} : valor superior de controle de contradição;

V_{icct} : valor inferior de controle de contradição;

Os eixos dos graus de contradição e de certeza, mais os limites citados acima são mostrados na figura 1.12:

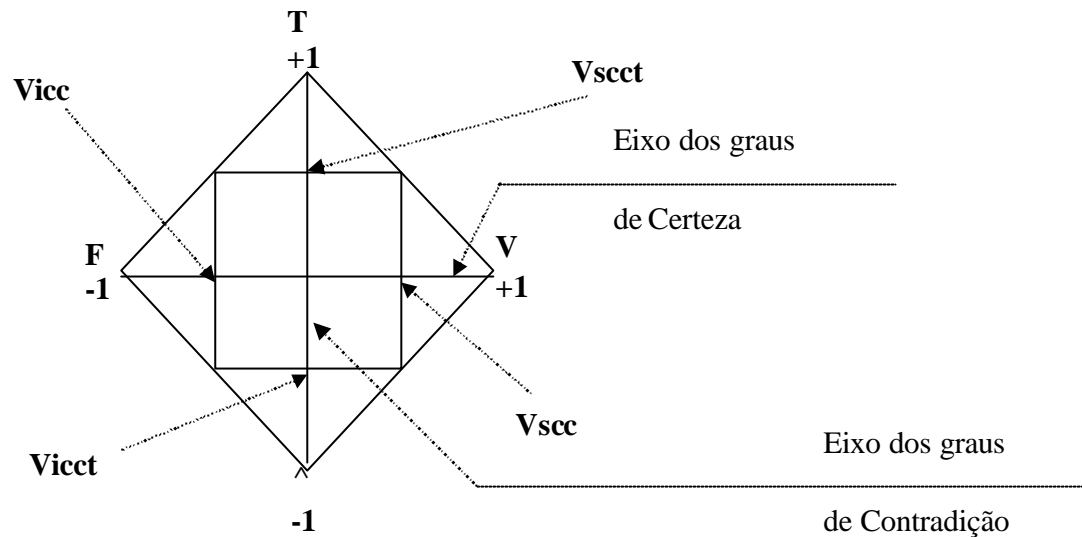


Figura 1.12. Representação dos eixos dos graus de Certeza e de Contradição.

Os limites externos do reticulado (em módulo) V_{sc} , V_{icc} , V_{scct} e V_{icct} dependem do parâmetro que esteja sendo modelado. Os dois limites V_{sc} e V_{icct} determinam quando o grau de Certeza resultante é alto o suficiente para que a proposição analisada seja considerada verdadeira ou falsa. Por outro lado, os dois limites V_{scct} e V_{icct} determinam quando o grau de Contradição resultante é alto o suficiente para que a proposição analisada seja considerada totalmente consistente ou totalmente inconsistente.

1.9.5 Algoritmo Para-analisador simplificado

O algoritmo *Para-analisador* foi edificado nas obras *Métodos de interpretação da Lógica Paraconsistente Anotada com anotação com dois valores LPA2v com construção de Algoritmo e implementação de Circuitos Eletrônicos e Fundamentos das Redes Neurais Artificiais Paraconsistentes* (Da Silva Filho, 1999; Da Silva Filho e Abe,

2001a). Sua versão simplificada pode ser apresentada de acordo com os seguintes passos:

1. Entrar com os valores V_{icc} , V_{scc} , V_{icct} e V_{scct} ;
2. Entrar com os valores de μ e λ ;
3. Calcular o Grau de Contradição : $G_{ct(\mu, \lambda)} = (\mu + \lambda) - 1$
4. Calcular o Grau de Certeza : $G_{ce(\mu, \lambda)} = \mu - \lambda$
5. Determinar os estados lógicos de saída:
 - a) se $G_c \geq V_{scc}$, então $S1 = V$;
 - b) se $G_c \leq V_{icc}$, então $S1 = F$;
 - c) se $G_{ct} \geq V_{scct}$, então $S1 = T$;
 - d) se $G_{ct} \leq V_{icct}$, então $S1 = \perp$;
 - e) se não $S1 = I$ (indefinição)

onde $S1$ é o valor lógico da saída do sistema.

1.9.6 Célula Artificial Paraconsistente básica

Inspirado no algoritmo Para-analisador, pode-se construir uma célula neural artificial que é denominada Célula Artificial Paraconsistente básica (CAPb). Outras células artificiais paraconsistentes, assim como células neurais artificiais paraconsistentes, são construídas a partir da mesma. A figura 1.13 mostra o esquema da Célula Artificial Paraconsistente básica:




Figura 1.13. Esquema da Célula Artificial Paraconsistente básica.

No esquema da figura 1.13 tem-se as entradas μ e λ , que são os graus de evidência favorável e contrária da informação com ($0 \leq \mu \leq 1$ e $0 \leq \lambda \leq 1$), bem como os limites V_{ic} , V_{sc} , V_{scct} e V_{icct} .

Como saídas têm-se $S2a = G_{ct}$ (Grau de Contradição), $S2b = G_{ce}$ (Grau de Certeza), e $S1$ que pode receber os estados lógicos T ou F ou V ou \perp ou I , sendo I interpretado como uma indefinição.

1.9.7 Célula Neural Artificial Paraconsistente

De acordo com estudos apresentados por Abe e Da Silva Filho (Abe, 1992; Da Silva Filho e Abe, 1998; Da Silva Filho, 1999) sobre Lógica Paraconsistente Anotada, em tal lógica, pode-se manipular em seu interior, incertezas, contradições ou inconsistências e/ou paracompleteza de modo não trivial. Nesses trabalhos foram edificados um analisador paraconsistente e um controlador lógico denominado *Paracontrol*, de onde foram sugeridas algumas aplicações ligadas à Robótica (Da Silva Filho, 1999) e análise de sinais (Mario, 2003).

Tais idéias inspiraram na confecção de um modelo de célula neural, que verificou-se possuir propriedades que permitem aceitar e tratar sinais difusos, contraditórios e paracompletos. Combinando-se várias destas células, forma-se a estrutura de uma rede onde o conjunto de células interligadas pode armazenar dados e manipulá-los.

A unidade básica da rede é fundamentada no algoritmo *Para-analisador* e denomina-se Célula Neural Artificial Paraconsistente (CNAP). As Células Neurais Artificiais Paraconsistentes, quando conectadas para uma determinada função, formam as Unidades Neurais Artificiais Paraconsistentes (UNAPs), que por sua vez quando agrupadas, formam as Redes Neurais Artificiais Paraconsistentes (RNAPs). A edificação da teoria das Redes Neurais Artificiais Paraconsistentes foi apresentada pela primeira vez no livro *Fundamentos das Redes Neurais Artificiais Paraconsistentes - destacando aplicações em Neurocomputação* (Da Silva Filho e Abe, 2001a). Um resumo dos conceitos das Redes Neurais Artificiais Paraconsistentes baseado nessa referência, é apresentado a seguir.

1.9.8 Célula Neural Artificial Paraconsistente básica

A figura 1.14 mostra uma Célula Neural Artificial Paraconsistente básica (CNAPb) com suas entradas e saídas:




Figura 1.14. Célula Neural Artificial Paraconsistente básica.

Entradas μ e λ : graus de evidência favorável e contrária da informação, onde $(0 \leq \mu \leq 1)$ e $(0 \leq \lambda \leq 1)$.

Na Célula Neural Artificial Paraconsistente básica, o resultado da análise vem em forma de um valor analógico do grau de certeza ($G_{ce} = \mu r$). O grau de certeza de uma célula, no interior de uma rede, é transferido a outras células, neste caso como informação de entrada (grau de evidência favorável).

Quando várias CNAPbs estão interligadas, os valores de saída devem ser normalizados para o intervalo [0, 1].

Conforme apresentado em (Da Silva Filho e Abe, 2001a) as informações podem ser recebidas através de sensores entre as células que trazem sinais de valores reais entre 0 e 1, para serem considerados na forma de grau de evidência favorável. A ponderação de valores e a troca de informações para processamento é feita pelas inúmeras conexões da rede através de sua Equação Estrutural Básica (EEB):

$$\mu_r = \frac{m - l + 1}{2}, \quad (1.4)$$

onde μ_r é a saída resultante, μ é a evidência favorável e λ é a evidência contrária.

1.9.9 Unidades Neurais Artificiais Paraconsistentes

As Unidades Neurais Artificiais Paraconsistentes (UNAPs) podem ser, a grosso modo, comparadas aos blocos componentes estruturais da rede de neurônios biológicos do cérebro. Estes blocos são interligados para que possam efetuar análises em conjunto, formando os “Sistemas Neurais Artificiais Paraconsistentes” de raciocínio lógico. Quando interligados desta forma, o conjunto de UNAPs apresenta funcionamento paralelo e distribuído com a capacidade de tratar sinais de forma analógica. Esta característica permite a elaboração de projetos de software aplicativos em linguagem de programação convencional.

1.9.10 Estrutura de uma Rede Neural Artificial Paraconsistente

A estrutura de uma Rede Neural Artificial Paraconsistente é composta hierarquicamente, cuja base é formada pelas CNAPs, que interligadas formam as Unidades Neurais Artificiais Paraconsistentes (UNAPs). A interligação destas UNAPs formam, por sua vez, as Redes Neurais Artificiais Paraconsistentes (RNAPs). Esta hierarquia é representada através do esquema da figura 1.15:

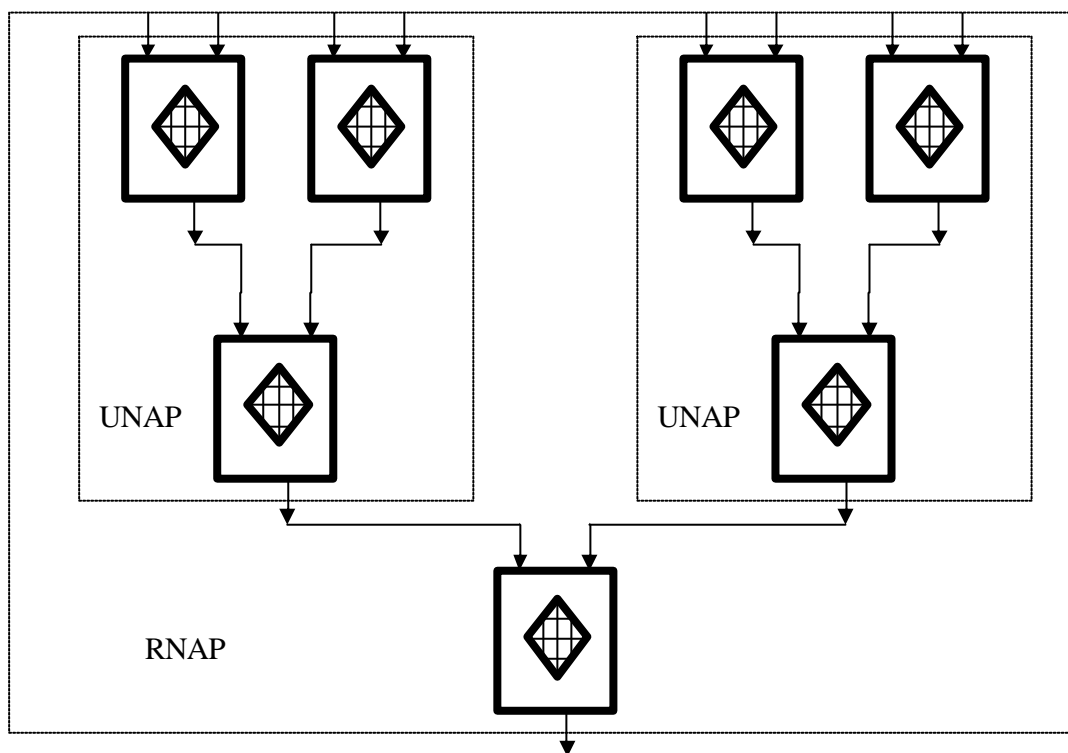


Figura 1.15. Exemplo de Unidades Neurais Artificiais Paraconsistentes formando uma Rede Neural Artificial Paraconsistente.

1.9.11 Célula Neural Artificial Paraconsistente de aprendizagem

Conforme demonstrado nos estudos realizados por Da Silva Filho e Abe (Da Silva Filho e Abe, 2001a), uma Célula Neural Artificial Paraconsistente de aprendizagem (CNAPa) pode aprender qualquer valor real, no intervalo fechado $[0, 1]$, aplicado em sua entrada $\mu_{1r}(k)$. O valor a ser “aprendido” é chamado de padrão μ_{1r} , e é aplicado na entrada da célula. A entrada complementada, C , é realimentada pela saída da célula. O valor inicial para a entrada complementada é 0.5, o que equivale na LPA2v a um valor indefinido. Portanto, este será o valor usado na inicialização da célula de aprendizagem.

No processo de aprendizagem é introduzido um fator de aprendizagem (F_a), que é ajustado externamente, e que influencia na rapidez do processo de aprendizagem. Quando $F_a = 1.0$, a aprendizagem é otimizada (Da Silva Filho e Abe, 2001a). A equação de aprendizagem é definida como:

$$\mu_{1r}(k+1) = [(\mu_{1r}(k) - (1 - \lambda) \times F_a) + 1] / 2 \quad (1.5)$$

Estudos realizados em (Mario, 2003) demonstraram que o processo de aprendizagem necessita ser repetido, ao menos, 15 vezes ($k = 15$) para que o processo ocorra por completo, com $F_a = 1$. Considera-se que o processo de aprendizado foi completado quando $\mu_{1r}(k+1) = \mu_{1r}(k)$. A figura 1.16 mostra a representação simbólica da célula:

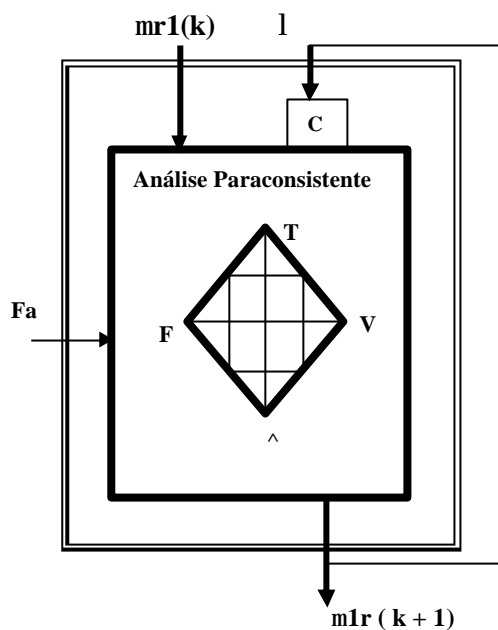


Figura 1.16. Célula Neural Artificial Paraconsistente de aprendizagem.

1.9.12 Célula Neural Artificial Paraconsistente de Conexão Lógica analítica

A Célula Neural Artificial Paraconsistente de Conexão Lógica analítica (CNAPCa) tem a função de fazer a interligação entre as células da Rede Neural Artificial Paraconsistente, associando graus de evidência conforme os objetivos da análise. A célula de conexão é o elo de ligação que permite a diferentes regiões de uma Rede Neural Artificial Paraconsistente efetuar o processamento de sinais de forma distribuída, por meio de inúmeras conexões paralelas (Da Silva Filho e Abe, 2001). A figura 1.17 mostra a representação simbólica de uma célula de conexão:




Figura 1.17: Célula Neural Artificial Paraconsistente de Conexão Lógica analítica

A seguir o algoritmo da CNAPCa (Da Silva Filho e Abe, 2001a):

$Ftc = C_1$ - Fator de tolerância à certeza: $0 \leq C_1 \leq 1$.

$Ftct = C_2$ - Fator de tolerância à contradição: $0 \leq C_2 \leq 1$.

μ = Grau de evidência favorável de entrada: $0 \leq \mu \leq 1$.

λ = Grau de evidência contrária de entrada: $0 \leq \lambda \leq 1$.

são calculados:

$$\lambda_C = 1 - \lambda: \text{complemento do grau de evidência contrária} \quad (1.6)$$

$$|Gct| = |\mu + \lambda_C - 1|: \text{valor do grau de contradição} \quad (1.7)$$

$$|Gce| = |\mu - \lambda_C|: \text{valor do grau de certeza} \quad (1.8)$$

$$Vicc = (1 - C_1) / 2: \text{valor do limite inferior de certeza} \quad (1.9)$$

$$Vsc = (1 + C_1) / 2: \text{valor do limite superior de certeza} \quad (1.10)$$

$$\mu_{1r} = (\mu - \lambda_C + 1) / 2 : \text{valor do grau de crença resultante} = \text{EEB} \quad (1.11)$$

saídas:

se $V_{icc} \leq \mu_{1r} \leq V_{sc}$: $S_1 = \mu_{1r}$ e $S_2 = 0$;

se $|G_{ct}| \geq C_2$ e $|G_{ct}| \geq |G_{ce}|$: $S_1 = 1/2$ e $S_2 = |G_{ct}|$;

senão: $S_1 = 1/2$ e $S_2 = 0$;

1.10 Técnicas de Inteligência Artificial aplicadas à análise cefalométrica

Os tópicos abordados até aqui estão relacionados com o desenvolvimento da análise cefalométrica que este trabalho se propõe a realizar. A análise cefalométrica é implementada dentro de uma arquitetura composta por blocos constituídos a partir dos conceitos expostos.

Células Neurais de Conexão Lógica analítica são utilizadas para receber e normalizar variáveis craniométricas. Uma Rede Neural Artificial Paraconsistente, inspirada nas Redes Neurais Artificiais, é utilizada para quantificar eventuais discrepâncias destas variáveis, tendo como referência padrões que passaram anteriormente por um processo de aprendizagem no interior da própria rede. Os resultados obtidos neste processo, podem ou não ser agrupados de acordo com a conveniência da análise, e passam a alimentar um Sistema Especialista, composto por regras que avaliam os resultados das quantificações efetuadas pela rede, apresentando na saída um diagnóstico relacionado à situação. O emprego das Redes Neurais Artificiais Paraconsistentes é especialmente conveniente neste ambiente em que as entradas

fornecidas pelo usuário do sistema podem gerar dados contraditórios, e são possíveis as análises onde as informações provenientes dessas entradas são incompletas.

As características desta aplicação, como informações contraditórias, falta de informações e dificuldades em classificar um diagnóstico, foram determinantes para a escolha de uma arquitetura que pode ser classificada de híbrida, pois é construída a partir da convergência dos conceitos aqui discutidos.

2. OBJETIVOS

2.1 Objetivos

Um grande número de fatores estão envolvidos com a Cefalometria e o diagnóstico ortodôntico, estando os mesmos sujeitos à imprecisões tanto na medição quanto na interpretação dos dados, além da forte subjetividade envolvida na análise.

O objetivo deste trabalho é implementar um modelo capaz de realizar a análise cefalométrica com todas as características que lhe são inerentes, e disponibilizar através desta análise cefalométrica um diagnóstico ortodôntico. A ferramenta adotada consiste em usar a Lógica Paraconsistente Anotada, através do uso de Redes Neurais Artificiais Paraconsistentes.

Este modelo de análise cefalométrica serve como ferramenta de apoio ao ortodontista, pois disponibiliza, ao mesmo, um diagnóstico de referência.

Para o modelo de análise cefalométrica proposto neste trabalho efetuar um diagnóstico ortodôntico, são necessárias as variáveis craniométricas, além da idade e sexo do paciente. Inserindo esses dados no modelo, o mesmo fará a análise cefalométrica a partir de uma base de dados contendo valores de referência de normalidade, previamente armazenados em seu interior. Este processo disponibiliza ao ortodontista um diagnóstico sem que o mesmo tenha que consultar valores de referência de normalidade de variáveis craniométricas.

Para realizar a análise cefalométrica, o modelo faz a interação entre as discrepâncias anteroposterior, vertical, e as alterações dentárias, desde que esteja disponível uma quantidade mínima necessária de medidas cefalométricas do paciente. O modelo disponibiliza o diagnóstico e associa, ao mesmo, um grau de evidência com

valor mínimo igual a zero e valor máximo igual a um, que está relacionado à intensidade da discrepância.

Outro objetivo é disponibilizar o modelo de análise cefalométrica pela *internet* para que o mesmo possa ser utilizado por ortodontistas, e uma das condições para utilizá-lo seria que o usuário disponibilizasse as variáveis do paciente através do mesmo. Essas informações permitiriam a ampliação do banco de dados referente às características das medidas cefalométricas da população brasileira.

3. METODOLOGIA

3.1 Rede Neural Artificial Paraconsistente e análise cefalométrica

Optou-se pela Lógica Paraconsistente, através das Redes Neurais Artificiais Paraconsistentes, para efetuar a análise das variáveis craniométricas, prioritariamente por três motivos:

- A arquitetura da rede, baseada na interconexão de células que tratam de diferentes variáveis, permite uma análise contextualizada entre as variáveis que se pretende avaliar;
- A base teórica da Lógica Paraconsistente Anotada com dois valores trabalha com informações imprecisas, contraditórias ou mesmo com a falta de informações, situações frequentes na prática do diagnóstico ortodôntico;
- Uma das características do diagnóstico ortodôntico é que o mesmo classifica as discrepâncias em classes, porém a “linha” que divide essas classes é de difícil percepção, dificultando a classificação. A Rede Neural Artificial Paraconsistente pode atribuir às variáveis craniométricas dos pacientes, um valor “analógico” entre zero e um, relacionado a quanto essas variáveis divergem de sua similar normal. Do mesmo modo, as saídas relacionadas aos diagnósticos, podem estar indexadas a valores analógicos com a mesma variação de amplitude, relacionados a vários estados lógicos (a lógica clássica trabalha apenas com os estados *verdadeiro* e *falso*) que correspondem às diferentes classificações impostas pelo diagnóstico.

A Rede Neural Artificial Paraconsistente, para análise das variáveis craniométricas, está dividida em três unidades que armazenam como valores de referência de normalidade das variáveis craniométricas, aquelas obtidas do *Atlas de*

Crescimento Craniofacial (Martins et al., 1998). A divisão destas unidades está relacionada ao diagnóstico que cada uma é capaz de efetuar, em função das informações das variáveis armazenadas, como segue:

Unidade I - Maloclusão esquelética anteroposterior: possui os dados relativos às variáveis SNA, SNB, ANB e Wits.

Unidade II - Maloclusão esquelética vertical: possui os dados relativos às variáveis Se-Go, Na-Me, Na-ENA, SeNa/PP, SeNa/PO, SeNa/PM e Eixo Y.

Unidade III - Alterações dentárias: possui os dados relativos às variáveis U1.SN, U1.PP, U1-NA, L1.GoMe, L1.NB, L1-NB, L1.APG, L1- APG, e U1.L1.

Para cada uma das variáveis acima descritas nas três unidades, estão armazenados os valores de referência de normalidade, relativos a jovens de 6 a 18 anos, separados por sexo, e o respectivo desvio padrão relacionado ao valor de cada variável.

3.2 Estrutura das Unidades Neurais Artificiais Paraconsistentes

Cada Unidade Neural Artificial Paraconsistente é composta pelos seguintes módulos:

- a) Módulo de normalização: calcula o grau de evidência entre a diferença das medidas das variáveis dos pacientes e os valores de referência de normalidade, que estão armazenados neste módulo e categorizados por sexo e idade.
- b) Módulo de caracterização das funções de evidências: constrói as matrizes com todos os valores possíveis de graus de evidência relacionados às variáveis dos pacientes, moldando-os com diferentes valores de desvio padrão, o que proporciona aos graus de evidência uma maior ou menor atenuação.

- c) Módulo de aprendizagem: composto por uma célula de aprendizagem que “aprende” os valores das matrizes que contém os graus de evidência, passando a armazenar uma função equivalente a esses mesmos valores.
- d) Módulo de evidência: este módulo armazena as funções aprendidas pelas células de aprendizagem e retorna o grau de evidência modelado de acordo com o desvio padrão, quando uma variável do paciente é inserida na rede. A rede neural de evidência faz a chamada aproximação funcional, ou seja, armazena e executa a função que determina o grau de evidência de uma variável craniométrica.
- e) Módulo de diagnóstico: composto por um Sistema Especialista que implementa as regras que relacionam as combinações dos graus de evidência das variáveis dos pacientes a um diagnóstico específico relacionado a cada unidade.

A figura 3.1 mostra a conexão dos blocos das unidades neurais:

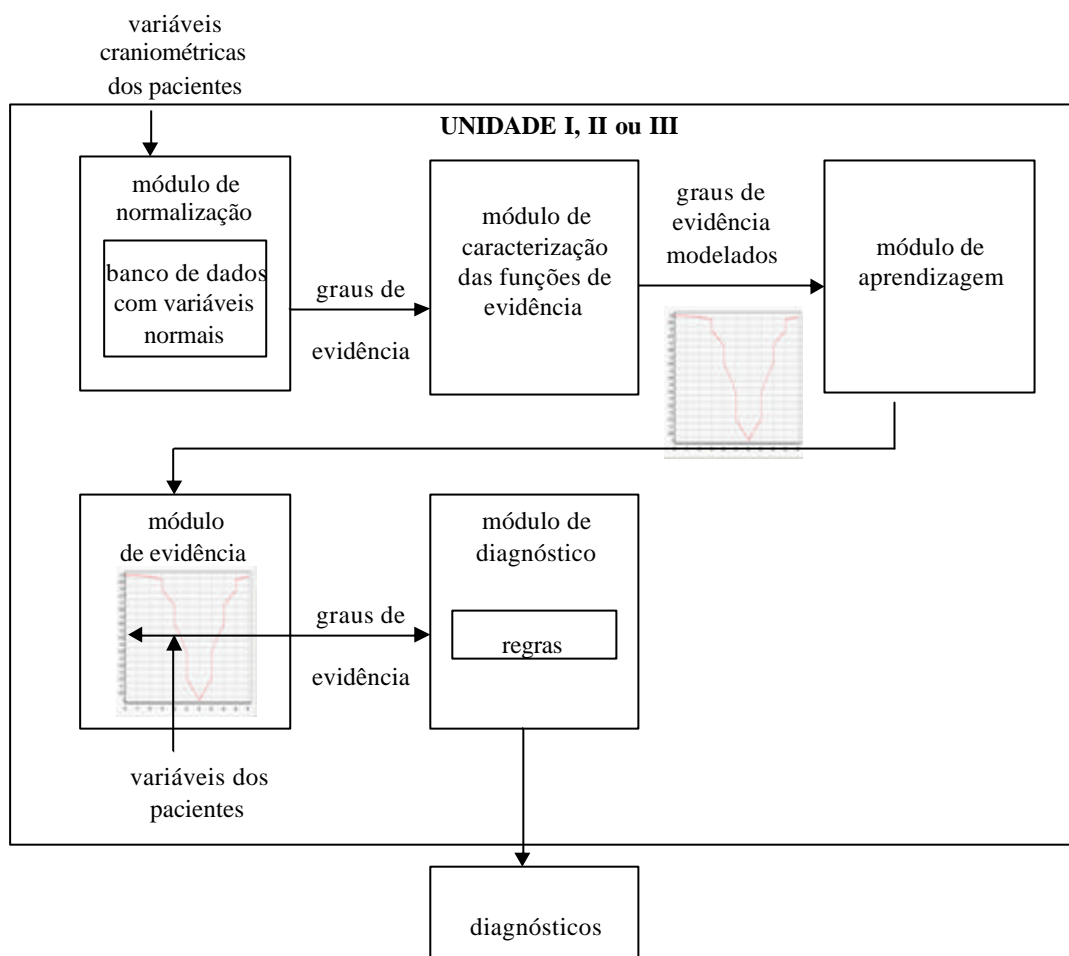


Figura 3.1. Conexão dos módulos da Rede Neural Artificial Paraconsistente de análise das variáveis craniométricas.

3.3 Módulo de normalização

A função do módulo de normalização é calcular um grau de evidência relacionado a variável craniométrica do paciente, sendo que este grau de evidência está em um intervalo entre zero e um, para que possa ser manipulado adequadamente através da Lógica Paraconsistente Anotada. O valor numérico, que é calculado e atribuído à variável craniométrica do paciente, está relacionado à discrepância que este apresenta

em relação ao valor de referência de normalidade da mesma, e é chamado grau de evidência da variável craniométrica.

Para quantificar a discrepância entre a medida de uma variável craniométrica do paciente e o valor de referência de normalidade, utilizou-se o desvio padrão, que é uma medida de dispersão que pode ser usada para medir a variabilidade de uma amostra (Massad et al., 2004). No *Atlas de Crescimento Craniofacial* (Martins et al., 1998) é fornecido o valor de referência de normalidade padrão da variável craniométrica, que representa a média obtida de uma amostragem, e o seu respectivo desvio padrão. Estendendo à aplicação, soma-se ou subtrai-se o valor de três vezes o desvio padrão ao valor de referência para quantificar a intensidade da discrepância relacionada à variável craniométrica. Por exemplo, se uma variável craniométrica tem valor de referência de normalidade igual a 30 e o desvio padrão correspondente de 6.3, subtraindo e somando o correspondente a três vezes o desvio padrão do valor de referência de normalidade, tem-se respectivamente os valores 11.1 e 48.9. Considerando este exemplo, se uma variável craniométrica do paciente se aproximar desses valores calculados (11.1 ou 48.9) o cálculo do grau de evidência correspondente a esta variável se aproximará de um. Desse modo, se a variável tivesse valor próximo a 30, o seu grau de evidência calculado seria próximo de zero. Portanto, o módulo de normalização efetua o cálculo do grau de evidência da variável do paciente, sendo que este valor é igual a zero se ela for igual ao seu valor de referência de normalidade, e se aproxima ou se iguala a um, se ela é superior ou inferior a três vezes o desvio padrão de seu valor de referência de normalidade.

Considerando estes conceitos, quando uma variável craniométrica é inserida no módulo de normalização, é considerada a seguinte proposição: “*a variável do paciente diverge da sua similar normal em... (grau de evidência relacionado)*”.

O processo de normalização das variáveis dos pacientes e criação das matrizes com os graus de evidência, é realizado pelas seguintes funções no programa, em cada unidade:

Unidade I - função anteroposterior: efetua a normalização das variáveis SNA, SNB, ANB e Wits.

Unidade II - função vertical: efetua a normalização das variáveis Se-Go, Na-Me, Na-ENA, SeNa/PP, SeNa/PO, SeNa/PM e EixoY.

Unidade III - função alterações dentárias: efetua a normalização das variáveis U1.SN, U1.PP, U1-NA, L1.GoMe, L1.NB, L1-NB, L1.APG, L1 - APG, e U1.L1.

3.3.1 Metodologia usada para determinação do grau de evidência de uma variável craniométrica

Quando uma variável craniométrica do paciente é inserida em uma das unidades, ela é comparada com um valor de referência de normalidade obtido do *Atlas de Crescimento Craniofacial* (Martins et al., 1998), e que está armazenado na própria rede. A comparação segue o critério de que a variável similar normal tenha sido obtida de pessoas com o mesmo sexo e idade do paciente. Como exemplo, é mostrado no apêndice 1, um trecho do programa que contém os valores de referência de normalidade da unidade II.

A seqüência da entrada da variável do paciente, sua normalização e o cálculo do seu grau de evidência é esquematizado a seguir, na figura 3.2:

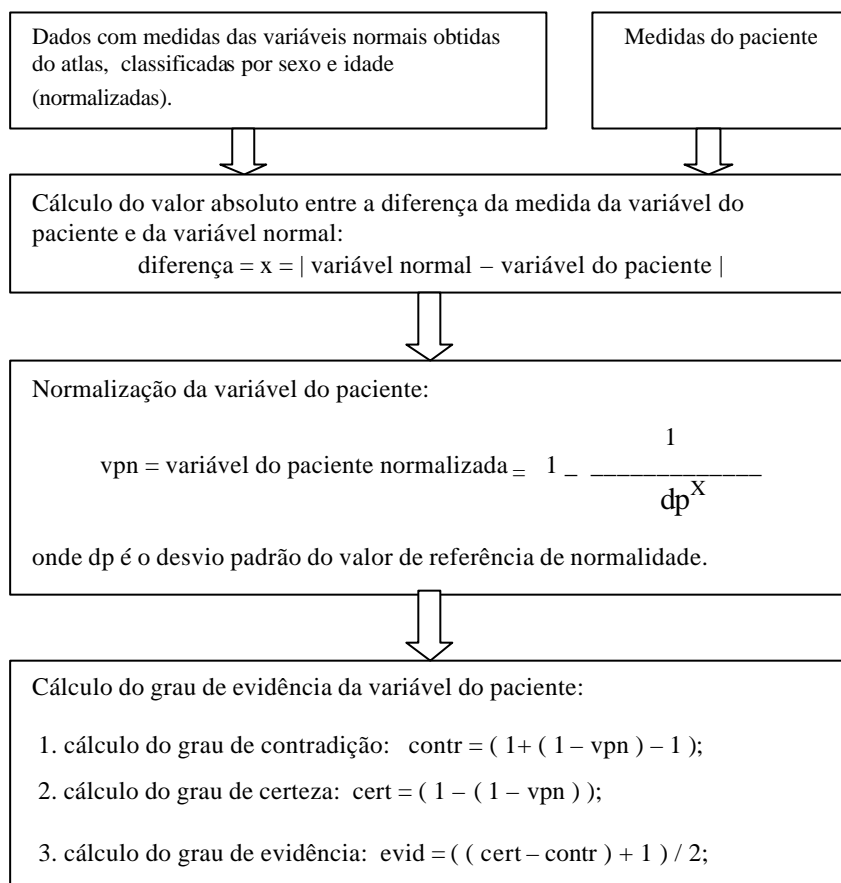


Figura 3.2. Esquema da normalização e do cálculo do grau de evidência da variável craniométrica do paciente.

O grau de evidência, de contradição e de certeza são obtidos a partir de uma Célula Neural Artificial Paraconsistente de Conexão Lógica analítica, mostrada na figura 3.3:

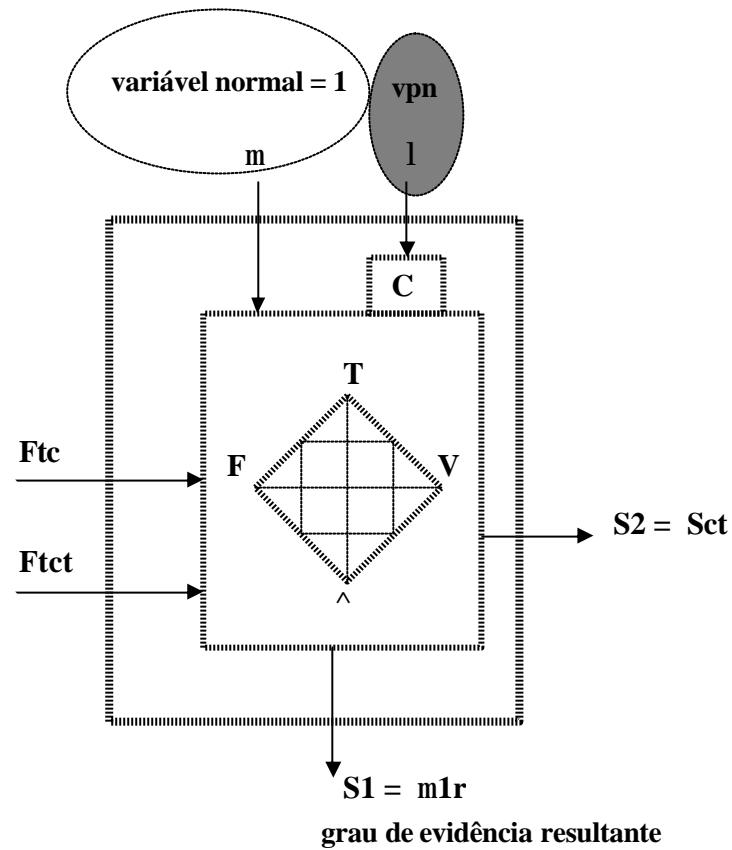


Figura 3.3. Célula Neural Artificial Paraconsistente de Conexão Lógica analítica, utilizada para calcular o grau de evidência das variáveis craniométricas dos pacientes.

A figura 3.4 ilustra o comportamento típico do grau de evidência em relação a vários valores de uma variável craniométrica do paciente.

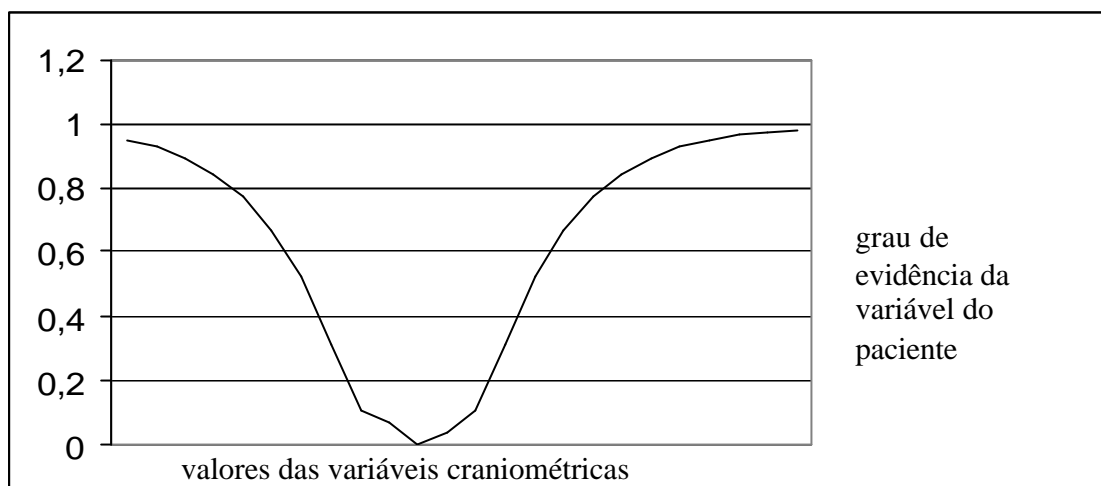


Figura 3.4. Curva que representa a variação do grau de evidência de uma variável do paciente. Quando a variável do paciente é igual a zero, então não há discrepância em relação à medida de uma variável similar normal.

3.4 Módulo de caracterização das funções de evidências

A curva da variação do grau de evidência para cada variável será moldada com o desvio padrão variando de acordo com os valores das variáveis. Tal efeito fará com que as curvas tenham diferentes inclinações de acordo com o valor das variáveis, e que apresente simetria a partir do valor de referência de normalidade (na figura este valor é igual a 82). Tal característica é mostrada na figura 3.5:

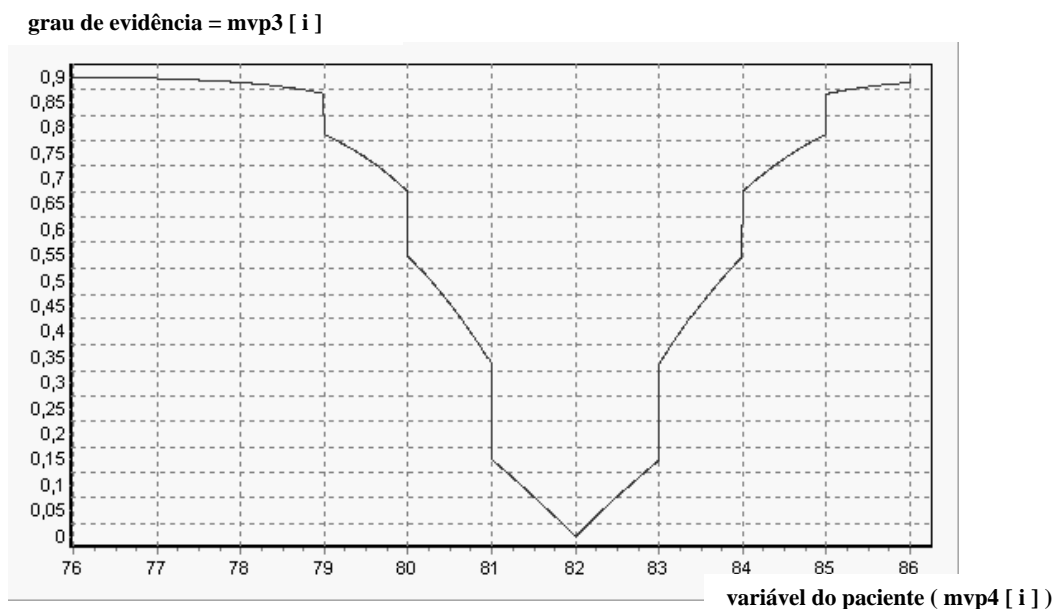


Figura 3.5. Formatação das curvas dos graus de evidência. Diferentes inclinações para faixas do valor das variáveis, obtidas com atribuição de diferentes valores de desvio padrão. No eixo x estão os valores das variáveis craniométricas dos pacientes, e no eixo y o grau de evidência atribuído a elas.

O processo de atribuição do desvio padrão de acordo com o valor das variáveis do paciente e a construção das matrizes com os graus de evidência é demonstrado a seguir:

- É inicializada uma matriz de mil pontos onde o valor inicial da matriz é definido como sendo o valor da variável normal menos aproximadamente três vezes o valor do desvio padrão. No exemplo da figura 3.5, o valor inicial da matriz seria 76. Esta matriz é denominada de mvp4 (matriz das variáveis dos pacientes).

$$\text{mvp4}[0] = 76; \quad (3.1)$$

- Na seqüência, para cada faixa de valores das variáveis dos pacientes, é atribuído um desvio padrão, dp. O critério de atribuição do desvio padrão é utilizar o desvio padrão determinado na tabela (Martins et al., 1998) para aquela variável (segundo os

critérios de idade e sexo), e atenuá-lo quando o valor da variável se aproxima do normal, o que implica em uma inclinação da curva mais suave, ou torná-lo mais acentuado à medida que o valor das variáveis se distanciam dos valores normais. Na curva do exemplo, o valor normal da variável é 82, e os extremos inferior e superior são respectivamente 76 e 86. Quando é atribuído o valor do desvio padrão, a matriz é incrementada em seus elementos, para atribuição de novos valores:

$$mvp[i+1] = mvp[i] + (10/1000); \quad (3.2)$$

como a matriz tem mil pontos, e nesse caso a variação entre o valor extremo superior e inferior é de dez unidades (86 – 76), o incremento é definido pela taxa 10/1000. A seguir, uma demonstração de parte do código referente à atribuição de valores do desvio padrão é apresentado. Uma seqüência completa é mostrada no apêndice 2:

```
enquanto ( i ≤ 1000 ) faça
  início
    se (mvp4[i ] ≥ 76) e (mvp4[i] < 77) então   (3.3)
      dp = 4.1;  mvp4[i+1] = mvp4[i] + (10/1000); ... (3.4)
    fim
```

- É calculado o valor absoluto da diferença entre cada elemento da matriz com os valores das variáveis dos pacientes e o valor de referência de normalidade para aquela idade e sexo, sendo, então, criada uma matriz com os valores das diferenças. Como no cálculo do grau de evidência, cada elemento dessa matriz é um expoente, daí ela ser chamada de “*me*” (matriz de expoentes);

$$me[i] = | vn - mvp4[i] |; \quad (3.5)$$

- A partir da matriz de expoentes $me[i]$, é definida a matriz com os graus de evidência das variáveis dos pacientes, denominada $mvp3[i]$. Por exemplo, quando $vn = mvp4[i]$, ou seja, quando a variável do paciente é igual ao valor normal, $me[i] = 0$, e, portanto, o denominador é igual a um, e o grau de evidência será zero.

$$mvp3[i] = 1 - \frac{1}{dp^{me[i]}} ; \quad (3.6)$$

$i = i + 1;$

fim

3.5 Módulo de aprendizagem

As matrizes $mvp3[i]$ com os graus de evidência geradas pelas funções “anteroposterior”, “vertical” e “alterações dentárias” serão aprendidas por Células Neurais Artificiais Paraconsistentes de aprendizagem (figura 3.6);

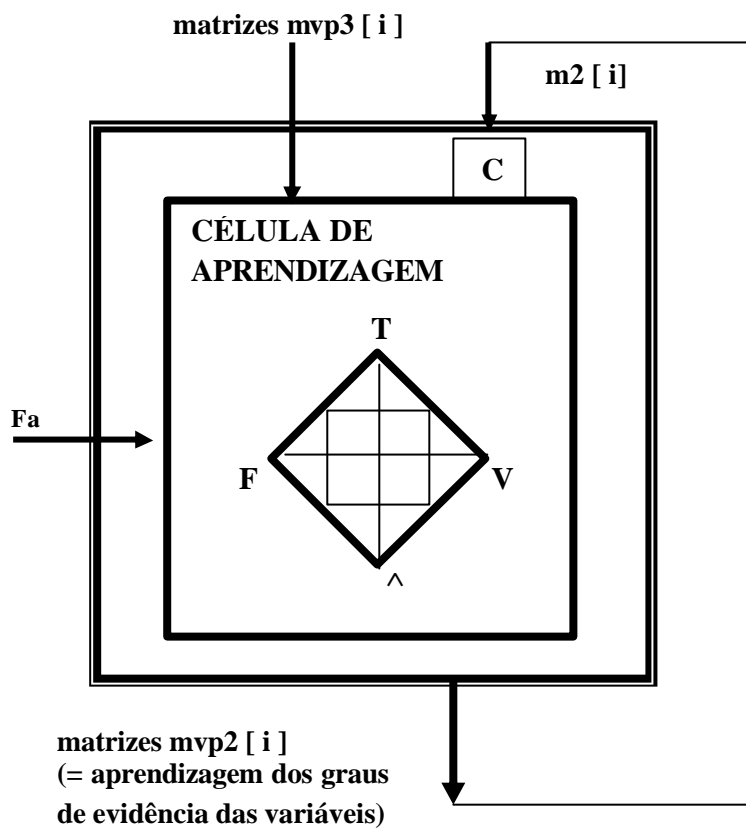


Figura 3.6. Célula Neural Artificial Paraconsistente de aprendizagem.

O algoritmo para a célula de aprendizagem é descrito a seguir:

enquanto $(i \leq 1000)$ faça

($i = 1000$: cada elemento da matriz é “treinado” 1000 vezes)

início

$Fa = 1.0;$ $m2[0] = 0.5;$

(definição do fator de ajuste (Fa) e inicialização do grau de contradição ($m2$))

enquanto $k \leq 20$ faça

($k =$ número de vezes que cada elemento da matriz será treinado)

```

início

    mvp2[k] = ( mvp3[i] - (1 - m2[k] ) * Fa + 1 ) / 2;
    m2[k+1] = mvp2[k];
    k = k+1;

fim;

i = i + 1;

fim;

```

(neste estágio cada elemento da matriz está treinado 20 vezes)

Segundo simulações efetuadas em (Mario, 2003) são necessários, ao menos, 15 treinamentos com $Fa = 1$, para que um valor analógico entre “0” e “1” seja completamente aprendido.

3.6 Módulo de evidência

As células de aprendizagem passam, então, a armazenar uma função com os graus de evidência relacionados aos valores das variáveis dos pacientes. O módulo de evidência é formado por unidades neurais artificiais capazes de receber a variável do paciente e, a partir da função que foi aprendida, determinar o grau de evidência dessa variável. Este processo é executado pelas seguintes estruturas (nas respectivas unidades):

Unidade I: Rede neural 1

Unidade II: Rede neural 2

Unidade III: Rede neural 3

Na seqüência, como exemplo, é mostrado trecho do algoritmo (da Rede neural 2), relativo à variável SNA;

início

```
msna2[j]=(( 1-1/(exp(me_sna*ln(dp_sna))))-(1-m2[k])*Fa+1)/2;
```

```
m2[k+1]= msna2[j];
```

```
k= k+1;
```

fim;

O trecho de programa destacado equivale à variável SNA do paciente inserida, e o efeito funcional é mostrado na figura 3.7:

graus de evidência



$(1-1/(exp(bb*ln(dp1)))) \gg 80$ entradas

Figura. 3.7. Funcionalidade e resposta da rede neural de evidência.

Logo, se a variável SNA do paciente em questão tiver valor 80, a rede neural responderá com um grau de evidência de 0,52.

3.7 Módulo de diagnóstico

O sistema especialista de diagnóstico é implementado em um trecho do programa chamado “sistema especialista” e recebe como entrada os graus de evidência estabelecidos pelas redes neurais, e a partir destes graus de evidência relativos a cada variável do paciente, estabelece, através de uma combinação de regras, o diagnóstico apropriado.

3.7.1 Sistema de regras da unidade I – discrepância anteroposterior

Esta unidade é dividida em dois níveis, sendo que o primeiro nível, ou nível I, trata das variáveis ANB e Wits, além de depender do valor da variável SeNa/PO. Se SeNa/PO tem valor acima de três vezes o desvio padrão, somente Wits é analisado para classificar a discrepância. Em contrapartida, se o valor de SeNa/PO está abaixo de três vezes o desvio padrão, somente ANB é considerado para classificar a discrepância. Esta análise resulta nas seguintes classificações para a discrepância anteroposterior:

- a) Classe I;
- b) Classe II; ou
- c) Classe III.

No segundo nível, ou nível II, há uma combinação entre o resultado obtido no nível I, os valores das variáveis SNB e SNA, e o resultado da análise da unidade II (discrepância esquelética vertical). A resposta do nível II se refere ao posicionamento da maxila e da mandíbula, classificando-as como:

- a) retruída;
- b) tendência à retruída;

- c) bem posicionada;
- d) tendência à protruída; ou
- e) protruída.

As classificações retruída e protruída vêm acompanhadas dos respectivos graus de evidência, enquanto que as classificações “tendência a” sugerem uma consulta aos diagnósticos da unidade II (discrepância esquelética vertical) e unidade III (alterações dentárias).

Um trecho das regras do nível I é descrito a seguir:

```

início
  //senafop alto prevalece só wits
  se ((msenafo2[j] >= 0.852) e (msenafo2[j] <= 1.0)) e
  (senafop > senafon) então
    início
      se (mwits2[j] > 0.68) e (mwits2[j] <= 1.00) e
      (witsp < witsn) então
        início
          t[j]=0.8; // classe III
        fim
      senão se (( mwits2[j] >= 0.65) e
      (mwits2[j] <= 0.68 )) e (witsp < witsn) então
        início
          t[j]=0.6; // tend. classe III
        fim
    fim
  ...

```

O apêndice 3 descreve o algoritmo onde estão implementadas todas as regras dos níveis I e II da unidade de discrepância anteroposterior.

3.7.2 Sistema de regras da unidade II – discrepância esquelética vertical

Nesse sistema, são combinadas as seguintes variáveis, divididas em três grupos distintos:

- a) grupo I: proporção Se-Go / Na-Me.
- b) grupo II: ângulo Eixo Y.
- c) grupo III: medidas SeNa/PP, SeNa/PO e SeNa/PM. Estas medidas são avaliadas individualmente, e combinadas para gerar o resultado deste grupo.

Cada grupo pode ser avaliado como “normal”, “vertical” ou “horizontal”. A combinação das avaliações dos grupos I, II e III, também resultará em uma avaliação “norma”, “vertical” ou “horizontal”. Ainda são fornecidos os graus de evidência das variáveis NaAns e AnsMe. O conjunto de regras da unidade II está no apêndice 4.

A medida SeNa/PO influencia a classificação da unidade I, nível I, quando SeNa/PO é muito alto ou baixo.

A classificação da unidade II, se “normal”, “vertical” ou “horizontal”, influencia a classificação da unidade I, nível II.

3.7.3 Sistema de regras da unidade III – alterações dentárias

Nesse sistema são combinadas as seguintes variáveis, divididas em três grupos distintos:

- a) grupo I: ângulos U1.PP, U1.SN e a medida U1-NA, levando em consideração o valor de SNA (unidade anteroposterior). O valor dessas variáveis pode resultar em três avaliações, ou seja, “normal”, “vestibularizado” ou “lingualizado”. Está sendo avaliada a posição dos incisivos superiores.
- b) grupo II: ângulos L1.Apg , L1.NB, L1.Gome e medidas L1-Apg, L1-NB, além de levar em consideração a variável SNB (também da unidade anteroposterior). O valor dessas variáveis pode resultar em três avaliações, ou seja, “normal”,

“vestibularizado” ou “lingualizado”. Está sendo avaliada a posição dos incisivos inferiores.

- c) grupo III: ângulo U1.L1. O valor dessa variável também resulta em uma das três avaliações; “normal”, “vestibularizado” ou “lingualizado”. Esta medida reforça os diagnósticos dos grupos I e II.

A combinação dos resultados dos grupos I, II e III resultará em uma avaliação do posicionamento dos incisivos superiores e inferiores como segue:

- a) vestibularizado;
- b) tende a vestibularizado;
- c) normal;
- d) tende a lingualizado; ou
- e) lingualizado.

As classificações “vestibularizado” e “lingualizado” vêm acompanhadas dos respectivos graus de evidência. O conjunto de regras da unidade III está no apêndice 5.

3.8 Análise da performance do sistema

Os resultados do método de análise cefalométrica foram comparados com os diagnósticos de três especialistas ortodontistas. Os mesmos 120 casos foram apresentados aos especialistas, no formato de formulário, conforme a figura 3.8.

Para avaliar a concordância entre os diagnósticos efetuados pelo método de análise cefalométrica e os diagnósticos dos especialistas, utilizou-se o *coeficiente Kappa* (Siegel e Castellan, 1988; Fleiss, 1981). A medida Kappa baseia-se no número de respostas concordantes entre os juízes, e mede o grau de concordância além do que seria

esperado somente pelo acaso. Essa medida de concordância varia entre o valor máximo “1”, que representa total concordância, e “0”, indicando que a concordância encontrada poderia ter ocorrido pelo acaso (*Laboratório de Epidemiologia e Estatística – LEE: www.lee.dante.br*). A tabela abaixo mostra uma interpretação dos valores do índice Kappa.

Valores do Kappa	Interpretação
< 0	Sem concordância
0 - 0.19	Concordância pobre
0.20 - 0.39	Concordância satisfatória
0.40 - 0.59	Concordância moderada
0.60 - 0.79	Concordância substancial
0.80 - 1.00	Concordância quase perfeita

Tabela 3.1: Interpretação do índice Kappa (Landis e Koch, 1977).

SOFTWARE PARA DIAGNOSTICO ORTODONTICO ELETRONICO – VALIDAÇÃO			Caso: <u>CA-1</u>
(Valor Médio para Idade/Sexo)	Valor Deste Paciente		Idade: <u>11</u>
			Sexo: <u>F</u>
DISCREPÂNCIA ANTEROPOSTERIOR	DISCREPÂNCIA VERTICAL	ALTERAÇÕES DENTÁRIAS	
SNA (<u>82</u>)	Se-Go (<u>68</u>)	U1.SN (<u>105</u>)	106
Posição da Maxila	Na-Me (<u>107</u>)	U1.PP (<u>113</u>)	118
Normal	NaENA (<u>50</u>)	U1.NA (<u>23</u>)	24
Tendência à Protruída	ENAMe (<u>62</u>)	Normal	
Protruída		Tendência à Vestibularização	
Tendência à Retruída		Vestibularizados	
Retruída		Tendência à Lingualização	
		Lingualizado	
SNA (<u>77</u>)	SeNa/PP (<u>8</u>)	L1.GoMe (<u>90</u>)	88
Posição da Mandíbula	SeNa/PO (<u>17</u>)	L1.NB (<u>25</u>)	17
Normal	SeNa/PM (<u>36</u>)	L1-NB (<u>4</u>)	3
Tendência à Protruída		L1-APG (<u>24</u>)	18
Protruída		L1-APG (<u>2</u>)	0
Tendência à Retruída		Normal	
Retruída		Tendência à Vestibularização	
ANB (<u>5</u>)	Eixo Y (<u>88</u>)	Vestibularizados	
Wits (<u>2</u>)		Tendência à Lingualização	
Discrepância AP	Tendência Vertical	U1.L1 (<u>130</u>)	133
Classe I	Normal	Normal	
Tendência à Classe II	Vertical	Baixo (Vestibularizado)	
Classe II	Horizontal	Alto (Lingualizado)	
Tendência à Classe III			
Classe III			

Figura 3.8. Modelo de formulário utilizado para diagnóstico dos especialistas – exemplo com os valores típicos padrões para uma menina de 11 anos e as respectivas medidas feitas na paciente.

3.8.1 Caracterização dos casos utilizados

Para testar o modelo de análise cefalométrica foram utilizados 120 prontuários do consultório de um ortodontista, situado em um bairro de classe média da cidade de São Paulo. A maioria dos casos testados são de crianças e adolescentes na faixa etária entre 6 e 18 anos. Do total de 120 pacientes avaliados, 22 tinham idade acima de 18 anos

(18.33%) porém nestes casos, são usados os valores de referência de normalidade da idade de 18 anos.

Dos 120 casos avaliados, 118 são de pacientes brancos e 2 são de asiáticos.

4. RESULTADOS

4.1 Resultados obtidos com o modelo de análise cefalométrica

Neste capítulo serão apresentados os resultados obtidos com o modelo de análise cefalométrica, em comparação com diagnósticos realizados por três especialistas em ortodontia. Serão apresentados os resultados em separado de cada unidade da Rede Neural Artificial Paraconsistente, citadas no capítulo 3.

4.2 Resultados da discrepância anteroposterior

Os comparativos entre os diagnósticos efetuados pelo modelo de análise cefalométrica e pelos especialistas para a posição da maxila são mostrados na tabela 4.1.

	Especialista 1 & modelo	Especialista 2 & modelo	Especialista 3 & modelo
Índice Kappa	0.343	0.289	0.369
Nível descritivo	$p < 0.001$	$p < 0.001$	$p < 0.001$
Intervalo de 95% de confiança do kappa: (inf. – sup.)	0.246 – 0.44	0.193 – 0.385	0.281 – 0.456

Tabela 4.1. Índice Kappa entre o modelo de análise cefalométrica e os especialistas para avaliação da posição da maxila.

A tabela 4.2 mostra os resultados comparativos da avaliação da posição da mandíbula.

	Especialista 1 & modelo	Especialista 2 & modelo	Especialista 3 & modelo
Índice Kappa	0.296	0.245	0.306
Nível descritivo	$p < 0.001$	$p < 0.001$	$p < 0.001$
Intervalo de 95% de confiança do kappa: (inf. – sup.)	0.211 – 0.381	0.143 – 0.347	0.225 – 0.386

Tabela 4.2. Índice Kappa entre o modelo de análise cefalométrica e os especialistas para avaliação da posição da mandíbula.

A tabela 4.3 mostra os resultados comparativos da avaliação da discrepância anteroposterior.

	Especialista 1 & modelo	Especialista 2 & modelo	Especialista 3 & modelo
Índice Kappa	0.592	0.265	0.552
Nível descritivo	$p < 0.001$	$p < 0.001$	$p < 0.001$
Intervalo de 95% de confiança do kappa: (inf. – sup.)	0.487 – 0.697	0.159 – 0.371	0.451 – 0.654

Tabela 4.3. Índice Kappa entre o modelo de análise cefalométrica e os especialistas para avaliação da discrepância anteroposterior.

4.3 Resultados da avaliação da discrepância vertical

Os resultados de concordância entre os especialistas e o modelo de análise cefalométrica para a discrepância vertical são mostrados na tabela 4.4.

	Especialista 1 & modelo	Especialista 2 & modelo	Especialista 3 & modelo
Índice Kappa	0.75	0.372	0.67
Nível descritivo	$p < 0.001$	$p < 0.001$	$p < 0.001$
Intervalo de 95% de confiança do kappa: (inf. – sup.)	0.617 – 0.882	0.238 – 0.506	0.543 – 0.796

Tabela 4.4. Índice Kappa entre o modelo de análise cefalométrica e os especialistas para avaliação da discrepância vertical.

4.4 Resultados da avaliação das alterações dentárias

Os resultados de concordância entre os especialistas e o modelo de análise cefalométrica para as alterações nos incisivos superiores são mostrados na tabela 4.5.

	Especialista 1 & modelo	Especialista 2 & modelo	Especialista 3 & modelo
Índice Kappa	0.443	0.216	0.454
Nível descritivo	$p < 0.001$	$p < 0.001$	$p < 0.001$
Intervalo de 95% de confiança do kappa: (inf. – sup.)	0.348 – 0.538	0.142 – 0.29	0.357 – 0.551

Tabela 4.5. Índice Kappa entre o modelo de análise cefalométrica e os especialistas para avaliação da posição dos incisivos superiores.

Os resultados para as alterações nos incisivos inferiores são mostrados na tabela 4.6.

	Especialista 1 & modelo	Especialista 2 & modelo	Especialista 3 & modelo
Índice Kappa	0.451	0.084	0.457
Nível descritivo	$p < 0.001$	$p = 0.054$	$p < 0.001$
Intervalo de 95% de confiança do kappa: (inf. – sup.)	0.357 – 0.545	-0.0020 – 0.17	0.357 – 0.557

Tabela 4.6. Índice Kappa entre o modelo de análise cefalométrica e os especialistas para avaliação da posição dos incisivos inferiores.

Os resultados para as alterações no ângulo U1.L1 (ângulo entre o incisivo superior e inferior) são mostrados na tabela 4.7.

	Especialista 1 & modelo	Especialista 2 & modelo	Especialista 3 & modelo
Índice Kappa	0.924	0.849	0.885
Nível descritivo	$p < 0.001$	$p < 0.001$	$p < 0.001$
Intervalo de 95% de confiança do kappa: (inf. – sup.)	0.798 – 1.0	0.722 – 0.975	0.758 – 1.0

Tabela 4.7. Índice Kappa entre o modelo de análise cefalométrica e os especialistas para avaliação do ângulo U1.L1.

4.5 Concordância entre as avaliações dos especialistas

A tabela 4.8 mostra a concordância, através do índice Kappa, entre as avaliações dos três especialistas, para todas as discrepâncias citadas neste capítulo.

	Índice Kappa para avaliações dos 3 especialistas	Nível descritivo	Intervalo de 95% de confiança do kappa: (inf. – sup.)
Posição da maxila	0.421	$p < 0.001$	0.355 – 0.487
Posição da mandíbula	0.404	$p < 0.001$	0.346 – 0.463
Discrepância anteroposterior	0.487	$p < 0.001$	0.425 – 0.55
Discrepância vertical	0.534	$p < 0.001$	0.458 – 0.611
Posição dos incisivos superiores	0.468	$p < 0.001$	0.411 – 0.524
Posição dos incisivos inferiores	0.418	$p < 0.001$	0.362 – 0.475
Ângulo entre os incisivos - U1.L1	0.838	$p < 0.001$	0.765 – 0.912

Tabela 48. Concordância entre os diagnósticos dos especialistas através do índice Kappa.

5. DISCUSSÃO

5.1 Análise dos resultados

Neste capítulo serão discutidos os resultados dos diagnósticos realizados pelo modelo de análise cefalométrica, comparando sempre com os diagnósticos efetuados pelos três especialistas. Sempre que possível será detalhado o critério que o modelo utilizou, esclarecendo eventuais diferenças em relação aos diagnósticos dos especialistas.

Como foram utilizados os prontuários de 120 pacientes, para que os três especialistas e o modelo de análise cefalométrica fizessem os diagnósticos, estes prontuários estão numerados de 1 a 120. Quando for necessário a referência a algum caso em particular, este será identificado através do respectivo número de prontuário.

5.2 Análise dos resultados obtidos na região anteroposterior

Considerando as cinco classificações de diagnóstico do modelo de análise cefalométrica para a discrepância anteroposterior e tendo como referência a classificação “classe I”, o diagnóstico pode ter dois “sentidos”: um para classificação “classe II” (“tendência à classe II” e “classe II”) e o outro para a classificação “classe III” (“tendência à classe III” e “classe III”).

Considerando um dos sentidos, o limiar que separa duas classificações que estejam em seqüência é de difícil definição, porém a opção por essa quantidade de categorias permite avaliar melhor o diagnóstico.

De acordo com a tabela 4.3, a interpretação do índice de concordância Kappa, entre o modelo e os especialistas 1 e 3 foi de “concordância moderada” (respectivamente 0.592 e 0.552). Entre o modelo e o especialista 2, o índice de concordância Kappa foi de

“concordância satisfatória” (índice Kappa de 0.265). Contudo em todos os casos o índice Kappa foi estatisticamente significativo ($p < 0.001$).

A interpretação do índice de concordância Kappa entre os diagnósticos feitos pelos três especialistas foi de “concordância moderada” (índice Kappa de 0.487), como pode ser visto na tabela 4.8.

Quando avaliam-se os intervalos de confiança Kappa, os resultados entre o modelo e os especialistas 1 e 3 estão de acordo com os resultados obtidos quando se compara a concordância somente entre os especialistas.

Nessa avaliação, em apenas um caso houve discordância de sentido, ou seja, o modelo diagnosticou “tendência à classe III” e um dos especialistas diagnosticou “tendência à classe II”.

Em dois casos, o modelo diagnosticou “classe III” e um dos especialistas “classe I”, e em outro caso um dos especialistas diagnosticou “classe II” e o modelo “classe I”.

Nas quatro situações citadas acima, há total concordância de diagnósticos entre dois dos especialistas e, nessas condições, o diagnóstico do modelo coincide com esses dois especialistas em três desses casos.

Nos casos 60 e 61 houveram valores de ANB altos e positivos dos pacientes, enquanto que o valor de Wits era negativo. Nestes casos a informação de ANB sugere que os pacientes têm uma “tendência à classe II” ou “classe II” enquanto a informação de Wits sugere que os mesmos têm “tendência à classe III” ou “classe III”. Devido a inconsistência desses dados, o programa não classificou a discrepância anteroposterior nestes dois casos (percentual de 1.67%). Os especialistas 1 e 3 classificaram os casos 60 e 61 como “classe I”, enquanto que o especialista 2 classificou-os como “tendência à classe

II”. Há de se ressaltar que no formulário utilizado pelos especialistas para os diagnósticos não havia a opção de rejeitar os diagnósticos sugeridos.

5.3 Análise dos resultados do posicionamento da maxila e da mandíbula

Considerando as cinco classificações de diagnóstico do modelo de análise cefalométrica para o posicionamento da maxila e da mandíbula, e tendo como referência a classificação “normal”, o diagnóstico também pode ter dois “sentidos”: um para o posicionamento protruído (“tendência à protruída” e “protruída”) e outro para o posicionamento retruído (“tendência à retruída” e “retruída”). Da mesma maneira que ocorre com a discrepância anteroposterior, considerando um dos sentidos, o limiar que separa duas classificações que estejam em seqüência é de difícil definição, e, na maioria dos casos avaliados pelos especialistas, constatou-se que SNA e SNB foram preponderantes para definição do diagnóstico. De acordo com a tabela 4.8, e considerando cinco categorias de diagnóstico, a interpretação do índice de concordância Kappa entre os três especialistas foi de “concordância moderada” (índice de 0.421 para posição da maxila e de 0.404 para posição da mandíbula).

Como foi dito anteriormente, o modelo de análise cefalométrica considerou a dependência entre as variáveis SNA e SNB, além dos diagnósticos resultantes da região anteroposterior e da discrepância vertical. Nestas condições, de acordo com as tabelas 4.1 e 4.2, a interpretação de concordância Kappa entre o programa e cada um dos especialistas foi de “concordância satisfatória” (o índice variou entre 0.245 e 0.369).

A maior concordância verificada a favor da análise dos especialistas, mostrada na tabela 4.8, pode ser creditada ao fato de que os mesmos utilizaram principalmente a

variáveis SNA e SNB para a avaliação, o que aumenta a possibilidade de diagnósticos coincidentes, em contrapartida ao modelo, que contextualiza SNA e SNB a outras variáveis craniométricas.

Considerando a soma dos 120 diagnósticos para avaliação da posição da mandíbula e da maxila, totalizando 240, efetuados pelos três especialistas, em apenas três situações ocorreram discordância de sentido, ou seja, o diagnóstico do modelo apontando para o sentido de “protruída” ou “retruída”, e o diagnóstico do especialista apontando para o sentido inverso. Esses três casos representam 1.25% do total de 240 diagnósticos (considerando o posicionamento da mandíbula e da maxila).

Nas mesmas condições citadas acima, em quatro situações ocorreram divergências do tipo: quando o modelo de análise cefalométrica diagnóstica “protruída” ou “retruída”, o especialista diagnóstica “normal”. O inverso também ocorreu, ou seja, o especialista diagnosticando a discrepância e o modelo apontando normalidade. Esses casos representam 1.67% do total.

Os diagnósticos citados acima não são coincidentes entre os especialistas, e pode-se perceber, nestes casos, que o diagnóstico efetuado pelo modelo é concordante com pelo menos um especialista.

De um total de 240 avaliações do posicionamento da maxila e da mandíbula, o modelo não soube avaliar 16 casos (6,67% do total), porque a combinação das variáveis analisadas levava a uma condição de inconsistência dos dados de entrada. Esses casos foram considerados como não concordantes no momento de calcular o índice de concordância Kappa.

Quando os dados são ditos inconsistentes, pode-se interpretar, por exemplo, SNA e SNB indicando um posicionamento da maxila e da mandíbula, e os diagnósticos resultantes da região anteroposterior e da discrepância vertical contradizendo o mesmo posicionamento. Estas situações são inerentes ao diagnóstico, e o método é susceptível às mesmas, resultando em uma falta de avaliação.

Para a concordância de diagnóstico da mandíbula e da maxila o índice Kappa foi estatisticamente significativo ($p < 0.001$) e quando avaliam-se os intervalos de confiança Kappa, os resultados entre o modelo e os três especialistas estão de acordo com os resultados obtidos quando se compara a concordância somente entre os especialistas.

5.4 Análise dos resultados da discrepância vertical

De acordo com a tabela 4.4, a interpretação de concordância Kappa entre o modelo os especialistas 1 e 3 foi de “concordância substancial” (os índices foram de 0.75 e 0.67); entre o modelo e especialista 2, a interpretação de concordância Kappa foi de “concordância satisfatória” (índice Kappa de 0.372).

Mesmo considerando satisfatórios os resultados desta avaliação, o número maior de diferenças apontadas entre a avaliação do modelo e o especialista 2 deve ter como explicação os diferentes critérios adotados, por este último, para a classificação da discrepância vertical.

De acordo com a tabela 4.8, a interpretação de concordância Kappa entre os diagnósticos feitos pelos três especialistas foi de “concordância moderada” (índice Kappa de 0.534).

Em três casos do total de 120 (percentual de 2.5%), quando o modelo diagnosticou “vertical”, um dos especialistas apontou “horizontal”, ocorrendo o inverso, também. Nesses mesmos três casos, há uma total concordância entre o diagnóstico do modelo e o diagnóstico dos outros dois especialistas.

Para a concordância de diagnóstico da discrepância vertical o índice Kappa foi estatisticamente significativo ($p < 0.001$). Quando avaliam-se os intervalos de confiança Kappa, os resultados entre o modelo e os especialistas 1 e 2 estão de acordo com os resultados obtidos quando se compara a concordância somente entre os especialistas.

5.5 Análise dos resultados do posicionamento dos incisivos superiores

De acordo com a tabela 4.5, a interpretação de concordância Kappa entre o modelo de análise cefalométrica e os especialistas 1 e 3 foi de “concordância moderada” (índices Kappa de 0.443 e 0.454). Entre o especialista 2 e o modelo a interpretação de concordância Kappa foi de “concordância satisfatória” (índice Kappa de 0.216).

De acordo com a tabela 4.8, a interpretação de concordância Kappa entre os três especialistas foi de “concordância moderada” (índice Kappa de 0.468).

De acordo com as cinco classificações de diagnóstico do modelo de análise cefalométrica para o posicionamento dos incisivos superiores, e tendo como referência a classificação “normal”, considerou-se o sentido “vestibularizado” de diagnóstico: (“tendência a vestibularizado” e “vestibularizado”); e no sentido “lingualizado”: (“tendência à lingualizado” e “lingualizado”).

Nestas condições, em 36 casos do total de 120, houve discordância entre o modelo e os três especialistas para os diagnósticos “normal”, “vestibularizado” ou “lingualizado” (percentual de 30 %).

Analizando os casos mais significativos, especificamente no diagnóstico do paciente 3, os três especialistas classificaram o posicionamento dos incisivos superiores como “vestibularizado”, e o modelo o classificou como “normal”. Na análise do modelo, a variável U1.SN, embora acima do valor normal, tem um grau de evidência baixo, quando relacionada ao desvio padrão (ver item 3.1.2). Nestas mesmas condições, U1.NA possui grau de evidência alto. Essas duas variáveis são conjugadas entre si e depois o resultado é conjugado com U1.PP, que também apresenta grau de evidência baixo, apontando para uma normalidade; a somatória desses resultados indica uma tendência à normalidade. Além desses fatores, para análise do posicionamento dos incisivos superiores, é considerada a variável SNA que, neste caso específico, tem grau de evidência baixo, tendendo também para a normalidade. Portanto, justifica-se o diagnóstico apresentado pelo modelo. Provavelmente, os especialistas enfocaram apenas as medidas U1.SN, U1.NA e U1.PP, acima dos valores padrões, para efetuar o diagnóstico.

No diagnóstico do paciente 25, dois especialistas classificaram o posicionamento dos incisivos superiores como “normal”, e o terceiro classificou-o como “tendência à lingualizado”. Contudo, o método classificou-o como “lingualizado”, com uma evidência baixa.

Para efetuar esse diagnóstico, o modelo de análise cefalométrica considerou, primeiro, o grau de evidência de SNA, que apresentava um valor alto no sentido de

“retruída”. Neste caso, o valor do grau de evidência de U1.PP (alto, no sentido de “lingualizado”), prevalece sobre a conjugação das variáveis U1.SN (“normal”) e U1.NA (baixo, no sentido de “lingualizado”). Daí, a classificação do modelo ser “lingualizado”.

No diagnóstico do paciente 41, os três especialistas apontaram para uma classificação dos incisivos superiores como “normal”, e o modelo classificou-os como “vestibularizados”. Nesse caso, SNA é normal e U1.NA é próximo do normal, porém U1.SN e U1.PP têm graus de evidência altos, que apontam para vestibularizado. Conjugando primeiro U1.SN e U1.NA, e depois associando o resultado com U1.PP, o modelo de análise cefalométrica deu como diagnóstico “vestibularizado” com grau de evidência moderado.

No caso do diagnóstico do paciente 48, dois especialistas o classificaram como “lingualizado”, o terceiro como “tendência à lingualizado”, e o modelo de análise cefalométrica classificou o diagnóstico como “normal”; o grau de evidência de SNA é alto, no sentido de “retruída”, portanto, é considerado apenas o valor de U1.PP para a classificação, que neste caso é “normal”, mesmo com U1.SN e U1-NA sinalizando para “lingualizado”.

No caso do paciente 53, dois dos especialistas diagnosticaram “normal”, e o terceiro diagnosticou “tendência à lingualizado”. O modelo de análise cefalométrica classificou “vestibularizado” com baixo grau de evidência, considerando que SNA possui um alto grau de evidência no sentido de “tendência à retruída” e, portanto, faz prevalecer a análise de U1.PP sobre U1.SN e U1-NA. Uma vez que U1.PP tem grau de evidência moderado no sentido de vestibularizado, considera-se que o modelo de análise

cefalométrica forneceu uma resposta coerente neste caso, considerando os critérios adotados.

Os outros casos de discordâncias entre o modelo de análise cefalométrica e os especialistas, se encaixam nas justificativas citadas acima, onde os diagnósticos do modelo de análise cefalométrica corresponderam aos critérios adotados.

Para a concordância de diagnóstico dos incisivos superiores o índice Kappa foi estatisticamente significativo ($p < 0.001$). Quando avaliam-se os intervalos de confiança Kappa, os resultados entre o modelo e os especialistas 1 e 3 estão de acordo com os resultados obtidos quando se compara a concordância somente entre os especialistas.

5.6 Análise dos resultados do posicionamento dos incisivos inferiores

De acordo com a tabela 4.6, o índice de interpretação de concordância Kappa entre o modelo de análise cefalométrica e os especialistas 1 e 3 foi de “concordância moderada” (índices Kappa de 0.451 e 0.457). Com o especialista 2, a interpretação de concordância Kappa foi de “concordância pobre” (índice Kappa de 0.084). Nesse caso em específico, como o nível descritivo foi muito alto ($p = 0.054$), o resultado não é estatisticamente significativo.

De acordo com a tabela 4.8, o índice de interpretação de concordância Kappa entre os três especialistas foi de “concordância moderada” (índice Kappa de 0.418).

Prevalecem os mesmos sentidos de diagnósticos do item 5.5. Vale destacar os casos mais significativos de discordâncias entre os especialistas e o modelo de análise cefalométrica. No diagnóstico do paciente 55, os três especialistas classificaram o posicionamento dos incisivos inferiores como “normal”, e o modelo de análise

cefalométrica classificou-os como “vestibularizados” com evidência baixa, porque SNB possui grau de evidência alto e, portanto, prevalece a análise da variável L1.GoMe que, neste caso, também possui um grau de evidência alto no sentido de “vestibularizado”.

No diagnóstico do paciente 60, os três especialistas classificaram os incisivos inferiores como “vestibularizados”, enquanto o modelo de análise cefalométrica classificou o posicionamento como “normal”. Neste caso, como SNB tem grau de evidência alto, prevalece a análise de L1.GoMe, com grau de evidência que aponta para a normalidade.

No diagnóstico do paciente 69, os especialistas classificaram-no como “normal”, provavelmente pelos valores de L1.NB, L1-NB, L1.APg e L1-APg que são próximos do “normal”. Porém, SNB tem grau de evidência alto, prevalecendo a análise de L1.GoMe, que também apresenta grau de evidência alto. Neste caso, o diagnóstico do modelo de análise cefalométrica foi “vestibularizado” com grau de evidência baixo.

No diagnóstico do paciente 87, dois especialistas o diagnosticaram como “lingualizado” e o outro classificou-o como “tendência à lingualizado”, provavelmente influenciados pelas L1.NB e L1.APg que possuem valores acima do normal no sentido de lingualizado. Neste caso, o modelo de análise cefalométrica classificou os incisivos inferiores como “normal”, porque SNB tem grau de evidência alto, prevalecendo a análise L1.GoMe, que tem grau de evidência apontando para a normalidade.

Todos os outros casos discordantes se enquadram nas análises acima. Não foram analisados os casos onde a classificação dos diagnósticos estão em seqüência (“lingualizado” e “tendência a lingualizado” ou “protruído” e “tendência a protruído”) pois nestes casos a linha que delimita-os é de difícil definição e, portanto, justificam-se

as diferenças entre os próprios especialistas e entre os especialistas e o modelo de análise cefalométrica.

Quando avaliam-se os intervalos de confiança Kappa para os incisivos inferiores, os resultados entre o modelo e os especialistas 1 e 3 estão de acordo com os resultados obtidos quando se compara a concordância somente entre os especialistas.

5.7 Análise dos resultados do ângulo entre os incisivos

A extração ou não dos incisivos pode ser definida através da análise do ângulo U1.L1. Esta análise pode fornecer três classificações para o posicionamento dos mesmos: “vestibularizados”, “normal” e “lingualizados”.

De acordo com a tabela 4.7, a interpretação de concordância Kappa entre a análise de cada um dos especialistas e o modelo de análise cefalométrica foi de “concordância quase perfeita” (índice Kappa variando entre 0.849 e 0.924) para o posicionamento dos lábios.

De acordo com a tabela 4.8, a interpretação de concordância Kappa entre os três especialistas foi “concordância quase perfeita” (índice Kappa de 0.838).

Para a concordância de diagnóstico da discrepância vertical o índice Kappa foi estatisticamente significativo ($p < 0.001$). Quando avaliam-se os intervalos de confiança Kappa, os resultados entre o modelo e os três estão de acordo com os resultados obtidos quando se compara a concordância somente entre os especialistas.

6. CONCLUSÕES

6.1 Modelo de análise cefalométrica utilizado como apoio ao diagnóstico ortodôntico

As avaliações dos especialistas foram realizadas dentro de um cenário em que lhes eram fornecidas as variáveis cefalométricas de cada unidade onde se pretendia realizar o diagnóstico, com os respectivos valores de referência de normalidade, e a partir daí, eram dadas as mesmas alternativas de classificações para as discrepâncias.

Neste contexto, observou-se que, principalmente nos diagnósticos do posicionamento da mandíbula, da maxila, e dos incisivos inferiores e superiores, quando não havia concordância entre os especialistas, isto se dava principalmente ao fato das análises serem feitas em torno de valores isolados das variáveis.

Em um cenário próximo do cotidiano real de um ortodontista, o mesmo dispõe de um raio X do crânio para analisar o paciente, de onde obterá as medidas cefalométricas necessárias. De posse dessas medidas, o uso do modelo de análise cefalométrica se torna uma ferramenta que fornece um diagnóstico de referência, pois todas as suas classificações são feitas considerando os valores de referência de normalidade das variáveis cefalométricas por sexo e idade, e sempre são utilizados os mesmos critérios para a análise.

A estrutura matemática do modelo permite que estes valores de referência de normalidade possam ser trocados e adaptados ao perfil étnico dos pacientes do ortodontista. O fato do modelo de análise cefalométrica já conter esses valores de referência de normalidade e poder trocá-los se necessário, é um facilitador para que o ortodontista utilize o mesmo como ferramenta de apoio.

6.2 Limitações do modelo de análise cefalométrica

Apesar das medidas cefalométricas serem de importância fundamental para o diagnóstico ortodôntico, o mesmo é complexo e tem uma dependência relevante em relação ao aspecto estético, ou seja, um paciente com medidas fora do padrão de normalidade pode não necessitar de nenhum tratamento, pois o mesmo pode apresentar um bom aspecto visual compensado pelos tecidos moles. O modelo de análise cefalométrica desenvolvido não leva em consideração os aspectos relacionados a tecidos moles.

Conforme discutido nos itens 5.2 e 5.3 (discrepância anteroposterior e posicionamento da maxila e da mandíbula), o modelo de análise cefalométrica deixou de realizar o diagnóstico em dois casos por receber dados contraditórios e/ou inconsistentes relacionados às variáveis craniométricas pertinentes. A classificação destes diagnósticos pelo modelo é feita a partir da combinação de certas evidências encontradas nos valores das variáveis craniométricas e, nestes casos em específico, estas evidências não estavam presentes.

Por exemplo, nos casos dos pacientes em que a discrepância anteroposterior não pode ser avaliada (casos 60 e 61) pelo modelo de análise cefalométrica (resultado do modelo = “indefinido”), ocorreu a seguinte particularidade: os valores de ANB e Wits são contraditórios (ANB dos pacientes é maior que o valor de referência de normalidade com grau de evidência alto, e Wits dos pacientes é menor que o valor de referência de normalidade com um grau de evidência também alto). Nestas condições, o critério do modelo de análise cefalométrica é verificar o valor da variável SeNa/PO. Se esta variável é maior que o valor de referência de normalidade com grau de evidência alto,

prevalece a avaliação de Wits. Se SeNa/PO é menor que o valor de referência de normalidade com grau de evidência alto então prevalece a avaliação de ANB. Ocorre que nos casos citados SeNa/PO era maior que o valor de referência de normalidade, porém com grau de evidência baixo.

Foi uma constante neste trabalho evidenciar que o modelo pode tratar dados inconsistentes ou contraditórios. Nos casos citados, como os valores das variáveis ANB e Wits são contraditórios, o modelo recorre a variável SeNa/PO, ou seja, busca tratar a inconsistência e/ou contradição dos dados, porém esta variável não tem um grau de evidência suficiente para definir a classificação da discrepância anteroposterior.

6.3 Utilização da Lógica Paraconsistente Anotada e outras estruturas de IA

O modelo de análise cefalométrica utilizou as Células Neurais Artificiais Paraconsistentes de Conexão Lógica analítica para efetuar a normalização das variáveis craniométricas dentro do intervalo numérico [0, 1]. Utilizou-se a proposição abaixo como referência para determinar os graus de evidência relacionados às variáveis craniométricas dos pacientes:

- *“a variável craniométrica diverge do valor de referência de normalidade com evidência...”*

e quanto maior a divergência, mais o grau de evidência se aproxima de um.

Tais conceitos poderiam ser implementados por outras estruturas matemáticas, como por exemplo a *Lógica Fuzzy*, onde há similaridade entre os *graus de pertinência* atribuídos aos elementos de um determinado conjunto (Massad et al., 2004) e os graus de evidência da Lógica Paraconsistente. A proposição citada acima, seria análoga a uma

proposição *fuzzy* obtida a partir de uma *variável lingüística fuzzy*, cujo valor é expresso qualitativamente por um termo lingüístico e quantitativamente por sua função de pertinência, que lhe atribui um grau de pertinência (Massad et al., 2004). Contudo a teoria de conjuntos *fuzzy* não trata o problema da inconsistência de dados, nem tem ferramentas para implementar funcionalidades como a aproximação funcional a partir de aprendizagem.

No modelo de análise cefalométrica, a variável craniométrica já normalizada com um grau de evidência é inserida em um segmento da Rede Neural Artificial Paraconsistente constituída por Células Neurais Artificiais de aprendizagem e por algumas unidades neurais que implementam funções específicas. Esta estrutura pode ser comparada às Redes Neurais Artificiais clássicas. Porém o treinamento de redes clássicas é normalmente lento e demanda máquinas com grande capacidade de processamento. Em comparação com as Redes Neurais Artificiais Paraconsistentes, o treinamento é rápido e dura em torno de poucos segundos em um computador convencional, podendo ser efetuado em tempo de execução do programa.

Por utilizar a Lógica Paraconsistente, o modelo de análise cefalométrica é constituído por funções matemáticas simples, que podem ser implementadas por várias linguagens de programação. Para implementar o modelo foi escolhido o *software Delphi 7.0*, que utiliza a linguagem *Object Pascal* e que permite gerar um executável do programa com a propriedade da portabilidade, ou seja, pode ser executado em qualquer máquina, mesmo que esta não possua o *software* instalado.

A simplicidade das funções matemáticas da Lógica Paraconsistente faz com que os programas que as implementam ocupem pouco espaço de memória. No programa em

questão, o seu executável tem o tamanho de 840KB, permitindo que o mesmo seja armazenado em um disquete de 1.44MB.

A saída da Rede Neural Artificial Paraconsistente alimenta um Sistema Especialista que irá implementar regras que determinarão o diagnóstico, que pode ser exemplificado abaixo com um exemplo da unidade III, que trata das alterações dentárias, neste caso em específico, dos incisivos superiores:

"Se o grau de evidência resultante da conjugação das variáveis U1.SN e U1.Na é maior que 0.91 e menor que 0.97, então os incisivos superiores são vestibularizados com grau de evidência..."

O uso da Lógica Paraconsistente permite, portanto, agregar os graus de evidência resultantes de sua análise a um Sistema Especialista de regras, o que caracteriza o modelo de análise cefalométrica como híbrido, pois utiliza mais de uma ferramenta de IA.

A Lógica Paraconsistente Anotada foi capaz de fazer um tratamento adequado, primeiro, como uma linguagem para poder expressar as nuances inerentes presentes na classificação dos diagnósticos; segundo, a estrutura dedutiva foi capaz de manipular mecanicamente e adequadamente as informações incertas, imprecisas ou mesmo conflitantes e/ou paracompletas. Por fim, constitui-se em ferramental útil na análise cefalométrica a que propusemos fazê-la e os resultados se mostraram adequados.

7. REFERÊNCIAS BIBLIOGRÁFICAS

7. Referências Bibliográficas

Abe JM. *Fundamentos da Lógica Anotada (Foundations of Annotated Logics)*, in Portuguese, Ph D thesis, University of São Paulo, FFLCH/USP - São Paulo; 1992.

Abe J.M. *Some Aspects of Paraconsistent Systems and Applications*, *Logique et Analyse*, 157:83-96; 1997.

Akama S, Abe JM. *Natural Deduction And General Annotated Logics*, atas do The First International Workshop on Labelled Deduction (LD'98), Freiburg, Alemanha, 1-14, 1998. Também publicado na Coleção Documentos, Série Lógica e Teoria da Ciência, IEA-USP, n^o 49, 14p.; 1998.

Akçam MO, Takada K. *Fuzzy modelling for selecting headgear types*. *European Journal of Orthodontics*, 24: 99-106; 2002.

Ávila BC. *Uma Abordagem Paraconsistente Baseada em Lógica Evidencial para Tratar Exceções em Sistemas de Frames com Múltipla Herança*, tese de Doutorado, Universidade de São Paulo, São Paulo; 1996.

Braga AP, Carvalho APLF, Ludemir TB. *Redes Neurais Artificiais: teoria e aplicações*. Livros Técnicos e Científicos, Rio de Janeiro – RJ; 2000.

Da Costa NCA, Abe JM. *Inteligência Artificial Paraconsistente*, atas do VI Congresso Brasileiro de Filosofia, 5 a 10 de setembro de 1999, Instituto Brasileiro de Filosofia, Faculdade de Direito da Universidade de São Paulo; 1999.

Abe JM, Da Silva Filho JI. *Implementação de circuitos eletrônicos de funções lógicas Paraconsistentes radix N*, Coleção Documentos IEA-USP, No33,32p., São Paulo; 1996.

Abe JM, Akama S, Da Silva Filho JI. *Modalities, paraconsistency, paracompleteness, and AI*, Atas do I Congresso de Lógica Aplicada à Tecnologia – LAPTEC'2000, Editôra Plêiade, São Paulo, SP – Brasil, Editor: J.M. Abe, ISBN 85-85795-29-8, 459-470; 2000.

Ackerman JL, Proffit WR, *Soft tissue limitations in Orthodontics: treatment planning guidelines*, 67-327, Angle Orthod; 1997.

Blok WJ, Pigozzi D. *Algebraizable Logics*, *Memoirs of the A.M.S.*, 77, No 396; 1989.

Buchanan BG, Shortliffe EH. *Rules-Based Expert Systems: The MYCIN Experiments of the Stanford Heuristic Programming Project*. Addison-Wesley, Reading, Massachusetts; 1984.

Buchanan BG, Sutherland GL, Feigenbaum EA. *Heuristic DENDRAL: A program for generating explanatory hypotheses in organic chemistry*. Edinburgh University Press, Edinburgh, Scotland; 1969.

Da Costa NCA, Abe JM, Subrahmanian VS. *Remarks on annotated logic*. Zeitschrift f. math. Logik und Grundlagen d. Math. 37, pp 561-570; 1991.

Da Costa NCA, Subrahmanian VS, Vago C. *The Paraconsistent Logic Pt.*. Zeitschrift für Mathematische Logik und Grundlagen der Mathematik, Vol.37, pp.139-148; 1991.

Da Silva Filho JI. *Implementação de circuitos Lógicos fundamentados em uma classe de Lógicas Paraconsistentes Anotada*, Dissertação de Mestrado-EPUSP, São Paulo; 1997.

Da Silva Filho JI. *Métodos de interpretação da Lógica Paraconsistente Anotada com anotação com dois valores LPA2v com construção de Algoritmo e implementação de Circuitos Eletrônicos*, EPUSP, Tese de Doutorado, São Paulo; 1999.

Da Silva Filho JI, Abe JM. *Algoritmo Para-analisador – Parte III: propostas de aplicações do algoritmo da lógica paraconsistente anotada de anotação com dois valores – LPA2v em sistemas especialistas de Inteligência Artificial*, Coleção Documentos, Série Lógica e Teoria da Ciência, IEA-USP, n.º 45, 15p. São Paulo; 1998.

Da Silva Filho JI, Abe JM. *Para-Fuzzy Logic Controller – Part I: A New Method of Hybrid Control Indicated for Treatment of Inconsistencies Designed with the Junction of the Paraconsistent Logic and Fuzzy Logic*, Proceedings of the International ICSC Congress on Computational Intelligence Methods and Applications - CIMA'99, Rochester Institute of Technology, RIT, Rochester, N.Y., USA, ISBN 3-906454-18-5, Editors: H. Bothe, E. Oja, E. Massad & C. Haefke, ICSC Academic Press, International Computer Science Conventions, Canada/Switzerland, 113-120; 1999a.

Da Silva Filho JI, Abe JM. *Para-Fuzzy Logic Controller – Part II: A Hybrid Logical Controller Indicated for Treatment of Fuzziness and Inconsistencies*, Proceedings of the International ICSC Congress on Computational Intelligence Methods and Applications - CIMA'99, Rochester Institute of Technology, RIT, Rochester, N.Y., USA, ISBN 3-906454-18-5, Editors: H. Bothe, E. Oja, E. Massad & C. Haefke, ICSC Academic Press, International Computer Science Conventions, Canada/Switzerland, 106-112; 1999b.

Da Silva Filho JI, Abe JM. *Fundamentos das Redes Neurais Artificiais Paraconsistentes - destacando aplicações em Neurocomputação*. São Paulo, Editora Villipress, Brazil; 2001a.

Da Silva Filho JI, Abe JM. *Paraconsistent analyzer module*, International Journal of Computing Anticipatory Systems, vol. 9, ISSN 1373-5411, ISBN 2-9600262-1-7, 346-352; 2001b.

Downs WB. *Variations in facial relationships: their significance in treatment and prognosis*. Am J Orthod. 34 (10): 812-40; 1948.

Massad M, Menezes RX, Silveira PSP, Ortega NRS. *Métodos Quantitativos em Medicina*, Editora Manole, pg 160-176. Barueri-SP; 2004.

Fleiss Joseph L. *Statistical methods for rates and proportions*. John Wiley, p 212-236. New York; 1981.

Harvold EP. *Some biologic aspects of orthodontic treatment in the transitional dentition*. Am J Orthod. 49 (1): 1 – 14; 1963.

Haykin S. *Neural Networks – A Comprehensive Foundation*. Prentice-Hall; 1994.

Haykin S. *Redes Neurais – Princípios e prática*. 2a ed.. Porto Alegre: Bookman; 2001.

Hebb DO. *The Organization of Behavior*. John Wiley & Sons; 1949.

Heckerman D. *Probabilistic Similarity Networks*. MIT Press, Cambridge, Massachussets; 1991.

Hopfield JJ. *Neurons with graded response have collective computational properties like those of two-state neurons*. Proceedings of the National Academy of Sciences of the United States of America, 79, 2554-2558; 1982.

Interlandi S. *Ortodontia – Bases para a Iniciação*. 4a ed.. Editora Artes Médicas – Divisão Odontológica, São Paulo; 1999.

Jacobson A. *The “Wits” appraisal of Jaw disharmony*. Am J Orthod. 67(2): 1 25-38; 1975.

Jabarak JR, Fizzel JA. *Technique and treatment with light wire edgewise appliances*. 2a. Ed. . v.1, p. 612, St. Louis Mosby; 1972.

Jarabak JR. *Aparatologia del arco de canto con alambres delgados*. Ed. Mundi SAIC y S., Buenos Aires – Argentina; 1975.

Jenkins DH. *A study of the dentofacial anatomy in normal and abnormal individuals employing lateral cefalometric radiography*. Am J Orthod. 41 (1): 149-50; 1955a.

Jenkins DH. *Analysis of orthodontic deformity employing lateral cephalostic radiography*. Am J Orthod. 41 (6): 442-52; 1955b.

Landis JR, Koch GG. *The measurement of observer agreement for categorical data*. Biometrics, 33: 159-174; 1977.

Langlade M. *Cefalometria Ortodôntica*. Tradução de Benvença MN. Livraria Editora Santos, São Paulo-SP; 1993.

Mario MC. *Proposta de Aplicação das Redes Neurais Artificiais Paraconsistentes como Classificador de Sinais Utilizando Aproximação Funcional*. Univ. Federal de Uberlândia, Dissertação de Mestrado, Uberlândia; 2003.

Martins DR, Janson GRP, Almeida RR, Pinzan A, Henriques JFC, Freitas MR. *Atlas de Crescimento Craniofacial*. Editora Liv. Santos. 280p. São Paulo – SP; 1998.

McCarthy J. *Programs with common sense*. In Proceedings of the Symposium on Mechanisation of Thought Processes, Vol. 1, pp. 77-84, London. Her Majesty's Stationery Office; 1958.

McCulloch W, Pitts W. *A logical calculus of the ideas immanent in nervous activity*. Bulletin of Mathematical Biophysics 5, 115-133; 1943.

Moyers RE, Bookstein FL. *A nova cefalometria. Requisitos para uma nova cefalometria*. In: Petrelli, E. Ortodontia Contemporanea, Sarvier, pg. 43. São Paulo; 1988.

Nakamatsu K, Abe JM, Suzuki A. *Defeasible Reasoning Between Conflicting Agents Based on VALPSN*, American Association for Artificial Intelligence - AAAI'99 Workshop on Agents' Conflicts, ISBN 1-57735-092-8, TR WS-99-08, AAAI Press – American Association for Artificial Intelligence, Menlo Park, California, USA, 20-27; 1999.

Nascimento Jr. CA, Yoneyama T. *Inteligência Artificial em Controle e Automação*. Editora Edgard Blücher – FAPESP, 1-7, São Paulo; 2000.

Nilsson NJ. *Principles of Artificial Intelligence*. Morgan Kaufmann, 1986.

Paes AT. *Itens essenciais em bioestatística*, Arq. Bras. Cardiologia, vol. 71, n.4, p. 575-580, São Paulo, 1998.

Pearl J. *Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference*. Morgan Kaufmann, San Mateo, California; 1988.

Prado JPA. *Uma Arquitetura em IA Baseada em Lógica Paraconsistente*, tese de Doutorado, Universidade de São Paulo; 1996.

- Rezende SO. *Sistemas Inteligentes – Fundamentos e Aplicações*. Editora Manole Ltda, 142, Barueri-SP; 2003.
- Ricketts RM. *Cephalometric Synthesis*. Am. J. Orthod. 46: 647 – 673; 1960.
- Riedel RA. *A cephalometric roentgenographic study of relation of the maxilla and associated parts to the cranial base in normal and malocclusion of the teeth (Master thesis)*, Northwestern University Dental School, Chicago; 1948.
- Riolo ML, Moyers RE, McNamara JAJr, Hunter WS. *An Atlas of Craniofacial Growth - Cephalometric Standards from the University School Growth Study*. The University of Michigan, Ann Arbor, 379p.. Michigan ; 1974.
- Rosenblatt F. *Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanisms*. Spartan, Chicago; 1962.
- Rumelhart DE, McClelland JL. *Parallel Distributed Processing*. MIT Press, Cambridge, Massachussets; 1986.
- Russell S , Norvig P. *Inteligência Artificial*. 2a ed.. Ed. Campus. São Paulo-SP; 2004.
- Sarver DM. *Esthetic orthodontics and orthognathic surgery*, Mosby, St Louis; 1998.
- Sassouni V. *Diagnosis and treatment planning via roentgenographic cephalometry*. Amer. J. Orthodont. 44 (6) 433-63; 1958.
- Siegel S., Castellan N. *Nonparametric Statistics for the Behavioral Sciences*. 2.ed.: McGraw-Hill, p 284-285, New York; 1988.
- Smolensky P. *On the proper treatment of connectionism., Behavioral and Brain Science..v 2, 1-74; 1988*.
- Steiner CC. *Cephalometrics for you and me*. Am. J. Orthod. 39 (10): 729 – 55; Oct. 1953.
- Stephens C, Mackin N. *The validation of an expert system rule-base for fixed appliance treatment planning*. European Journal of Orthodontics, 20: 569-578; 1998.
- Sorihashi Y, Stephens CD, Takada K. *An inference modeling of human visual judgement of sagittal jaw-base relationships based on cephalometry: Part II*. American Journal of Orthodontics and Dentofacial Orthopedics, 117: 303-11; 2000.
- Subrahmanian VS. *On the semantics of quantitative Logic programs*. Proc. 4 th. IEEE Symposium on Logic Programming, Computer Society press, Washington D.C.; 1987.

Takada K, Sorihashi Y, Stephens CD, Itoh S. *An inference modeling of human visual judgement of sagittal jaw-base relationships based on cephalometry: Part I* American Journal of Orthodontics and Dentofacial Orthopedics, 117: 140-7; 2000.

Torres CR. *Sistema Inteligente Paraconsistente para Controle de Robôs Móveis Autônomos*, Dissertação de Mestrado, Universidade Federal de Itajubá - UNIFEI, Itajubá; 2004.

Turing A. *Computing machinery and intelligence*. Mind, 59, 433-460; 1950.

Winograd S, Cowan JD. *Reliable Computation in the Presence of Noise*. MIT Press, Cambridge, Massachussets; 1963.

Documentos Eletrônicos:

Laboratório de Epidemiologia e Estatística – LEE: www@lee.dante.br.

APÊNDICE

Apêndice 1

Trecho de código do algoritmo que armazena variáveis craniométricas normais (unidade II):

```
se o paciente é feminino
    então
se (idade >= 6) e (idade <= 9) então
início
    menn = 103;
    sgon = 64;
    nansn = 47;
    ansmen = 60;
    senapn = 8;
    senafon = 31;
    senampn = 37;
    napmf n = 87;
fim
```

Todas as outras variáveis craniométricas são armazenadas no programa seguindo este princípio, seguindo os critérios de idade e sexo.

Apêndice 2

Trecho de código do algoritmo que atribui valores diferentes de desvio padrão, em diferentes trechos das matrizes que representam as funções com os graus de evidência das variáveis craniométricas:

```
início
```

```
se (mvp4[i ] ≥ 76) e (mvp4[i] < 77) então
```

```
  dp = 4.1;  mvp4[i+1] = mvp4[i] + (10/1000);
```

```
  senão se (mvp4[i] ≥ 77) e (mvp4[i] < 79) então
```

```
    dp =3.0;  mvp4[i+1]  = mvp4[i]+(10/1000);
```

```
  senão se (mvp4[i] ≥ 79) e (mvp4[i] < 80) então
```

```
    dp =2.0;  mvp4[i+1] = mvp4[i]+(10/1000);
```

```
  senão se (mvp4[i] ≥ 80) e (mvp4[i] < 81) então
```

```
    dp =1.6;  mvp4[i+1] = mvp4[i]+(10/1000);
```

```
  senão se (mvp4[i] ≥ 81) e (mvp4[i] < 83) então
```

```
    dp =1.2;  mvp4[i+1] = mvp4[i]+(10/1000);
```

```
  senão se (mvp4[i] ≥ 83) e (mvp4[i] < 84) então
```

```
    dp =3.0;  mvp4[i+1] = mvp4[i]+(10/1000);
```

```
  senão se (mvp4[i] ≥ 84) então
```

```
    dp =4.1;  mvp4[i+1] = mvp4[i]+(10/1000);
```

Apêndice 3

Código do algoritmo que implementa as regras de diagnóstico da unidade I:

Nível I

Observação:

- $t[j]$ é a matriz com os graus de evidência referentes a cada uma das saídas;
- $msenafo2[j]$, $mwits2[j]$ e $manb2[j]$ são as matrizes que contém os graus de evidência das variáveis craniométricas SeNa/PO, Wits e ANB, respectivamente.
- $senafop$, $witsp$ e $anbp$ são as variáveis craniométricas com os valores do paciente, para SeNa/PO, Wits e ANB, respectivamente.
- $senafon$, $witsn$ e $anbn$ são as variáveis craniométricas similares a SeNa/PO, Wits e ANB, normais.

Significado dos valores de $t[j]$:

$t[j]$	Significado da saída
0,05	Inconsistente, tendendo à Classe II
0,2	Classe II
0,4	Tendência à Classe II
0,5	Classe I
0,6	Tendência à Classe III
0,8	Classe III
0,95	Inconsistente, tendendo à Classe III

Código para o nível 1

```
início

    //senafop alto prevalece só wits

    se ((msenafo2[j] >= 0.852) e (msenafo2[j] <= 1.0)) e
    (senafop > senafon) então

início

    se (mwits2[j] > 0.68) e (mwits2[j] <= 1.00) e
    (witsp < witsn) então
    início
    t[j]=0.8; // classe III
    fim

    senão se (( mwits2[j] >= 0.65) e
    (mwits2[j] <= 0.68 )) e (witsp < witsn) então
    início
    t[j]=0.6; // tend. classe III
    fim

    senão se (mwits2[j] < 0.65) então
    início
    t[j]=0.5; // classe I
    fim

    senão se ((mwits2[j] >= 0.65) e (mwits2[j] <= 0.68))
    e (witsp > witsn) então
    início
    t[j]=0.4; // tend. classe II
    fim

    senão se ((mwits2[j] >= 0.68) e (mwits2[j] <= 1.0))
    e (witsp > witsn) então
    início
    t[j]=0.2; // classe II
    fim

fim
```

```

// senafo baixo: prevalece anb
senão se ((msenafo2[j] >= 0.852) e
(msenafo2[j] <= 1.0)) e (senafo < senafon) então

início

    se ((anbp < anb) e ((manb2[j] > 0.867) e
(manb2[j] <= 1.0))) então
    início
    t[j]=0.8; // classe III
    fim

    senão se ((anbp < anb) e ((manb2[j] > 0.6) e
(manb2[j] <= 0.867))) então
    início
    t[j]=0.6; // tend. classe III
    fim

    senão se (manb2[j] <= 0.6) então
    início
    t[j]=0.5; // classe I
    fim

    senão se ((anbp > anb) e ((manb2[j] > 0.6) e
(manb2[j] <= 0.867))) então
    início
    t[j]=0.4; // tend. classe II
    fim

    senão se ((anbp < anb) e ((manb2[j] > 0.867) e
(manb2[j] <= 1.0))) então
    início
    t[j]=0.2; // classe II
    fim
fim //senafo alto ou baixo

//anb e wits normais
senão se (manb2[j] <= 0.6) e (mwits2[j]<= 0.67) então
início
t[j]=0.5; // classe I
fim

```

```

//anb normal e wits alto
  senão se (manb2[j] <= 0.6) e (mwits2[j] > 0.67) e
  (mwits2[j]<= 1.00) e (witsp > witsn) então
  início
  t[j]=0.4; // tende a classe II
  fim

      // anb alto wits normal
senão se (anbp > anbn) e ((manb2[j] > 0.6) e
  (manb2[j] < 1.0)) e (mwits2[j]<= 0.67) então
  início
  t[j]=0.4; // tende a classe II
  fim

      // anb normal wits baixo
senão se (manb2[j] <= 0.6) e ((mwits2[j] > 0.67) e
  (mwits2[j] <= 1.00) e (witsp < witsn )) então
  início
  t[j]=0.6; // tende a classe III
  fim

      // anb baixo wits normal
senão se (anbp < anbn) e ((manb2[j] > 0.6) e
  (manb2[j] < 1.0)) e (mwits2[j]<= 0.67) então
  início
  t[j]=0.6; // tende a classe III
  fim

      //anb alto e wits alto
senão se (anbp > anbn) e ((manb2[j] > 0.6) e
  (manb2[j] < 1.0)) e ((mwits2[j] > 0.67) e
  (mwits2[j] <= 1.00)) e (witsp > witsn) então
  início
  t[j]=0.2; // classe II
  fim

      // falta informação de wits
senão se (anbp > anbn) e (manb2[j] > 0.55) e
  (mwits2[j] >= 1.11) então
  início
  t[j]=0.05; // região de inconsistência com
  tendência à classe II
  fim

```

```
        // anb baixo e wits baixo
        senão se ((anbp < anbn) e ((manb2[j] > 0.6) e
        (manb2[j] <= 1.0))) e (mwits2[j] > 0.67) e
        (mwits2[j]<= 1.00) e (witsp < witsn) então
        início
        t[j]=0.8; // classe III
        fim

        // falta informação de wits
        senão se ((anbp < anbn) e ((manb2[j] > 0.55) e
        (manb2[j] <= 1.0))) e (mwits2[j]>= 1.11) então
        início
        t[j]=0.95; // região de inconsistência com tendência à
        classe III
        fim

        senão //paracompleto
        início
        t[j]=1.11;
        fim;

fim;
```

Nível II

Observação:

- $t[j]$ é a matriz com os graus de evidência referentes a cada uma das saídas do nível I; $t1[j]$ é a matriz com os graus de evidência referentes a cada uma das saídas do nível II; $t9[j]$ é a matriz com os graus de evidência que classificam a unidade II (discrepância esquelética vertical) em normal, vertical ou horizontal.
- $msna2[j]$, $msnb2[j]$, $mwits2[j]$ e $manb2[j]$ são as matrizes que contêm os graus de evidência das variáveis craniométricas SNA, SNB, Wits e ANB, respectivamente.
- $snap$, $snbp$, $witsp$ e $anbp$ são as variáveis craniométricas com os valores do paciente, respectivamente para SNA, SNB, Wits e ANB.
- $senafon$, $witsn$ e $anbn$ são as variáveis craniométricas similares a SeNa/PO, Wits e ANB, normais.

Significado dos valores de $t1[j]$:

$t1[j]$	Significado da saída
$0,0 < t[j] < 0,1$	Inconsistente
$0,1 < t[j] < 0,3$	Protruída
$0,3 < t[j] < 0,49$	Tendência à protruída
$0,49 < t[j] < 0,51$	Normal
$0,51 < t[j] < 0,69$	Tendência à retruída
$0,7 < t[j] < 0,89$	Retruída
$0,9 < t[j] < 1,0$	Inconsistente

Código para o nível II

```
início // avaliação da maxila

//unidade I anb normal tende classe II
se ((msna2[j] >= 0.889) e (snap > snan)) e
((snbp <= snbn) e (msnb2[j]<= 0.6)) e ((mwits2[j]>=0.68)e
(mwits2[j]<=0.87) e (witsp > witsn)) então
início
t1[j]=0.42;
fim

//unidade I anb normal tende classe III
senão se ((msna2[j] >= 0.548) e (msna2[j] <= 1.0) e
(snap < snan)) e (manb2[j] <= 0.8) e ((mwits2[j] > 0.68) e
(mwits2[j] <= 1.00) e (witsp < witsn)) e (t9[j] > 0.4)
então
início
t1[j]=0.62; // tende a classe III
fim

//sna normal e tendência classe II (11)
senão se (msna2[j] <= 0.548) e (t[j] >= 0.4) e
(t[j]< 0.49999999) então
início
t1[j]=0.47;
fim

//sna normal e tendência classe III (15)
senão se (msna2[j] <= 0.548) e (t[j]> 0.5) e
(t[j] <= 0.6) então
início
t1[j]=0.52;
fim

//sna normal e quase classe II (13)
senão se (msna2[j] <= 0.548) e ( t[j] > 0.1) e
(t[j] < 0.3) então
início
t1[j]=0.27;
fim
```

```

//sna normal e quase classe II (13)
senão se ((msna2[j] > 0.889) e (snap > snan))e
((msnb2[j]> 0.674) e (snbp < snbn)) e (t9[j] < 0.5) então
início
t1[j]=0.29;
fim

//sna normal e quase classe III (17)
senão se (msna2[j] <= 0.548) e ( t[j]> 0.7) e
(t[j] < 0.9) então
início
t1[j]=0.72;
fim

//sna e snb normais e classe I (1 / 10)
senão se (msna2[j] <= 0.548) e (msnb2[j] <= 0.68) e
(t[j]>= 0.49999999) e (t[j] <= 0.50000001) então
início
t1[j]=0.5;
fim

// wits normal / sna e snb altos (33)
senão se ((msna2[j] >= 0.548) e (msna2[j] <= 1.0) e
(snap > snan) ) e ((msnb2[j] >= 0.6) e (msnb2[j] <= 1.0) e
(snbp > snbn)) e ( t[j]>= 0.49999999)e
(t[j] <= 0.50000001) então
início
t1[j]=0.54;
fim

// wits normal / sna e snb baixos (38)
senão se ((msna2[j] >= 0.548) e (msna2[j] <= 1.0) e
(snap < snan) ) e ((msnb2[j] >= 0.6) e (msnb2[j] <= 1.0)
e (snbp < snbn)) e ( t[j]>= 0.49999999) e
(t[j] <= 0.50000001) então
início
t1[j]=0.49;
fim

```

```

// wits e sna normal snb baixo (34)
  senão se (msna2[j] <= 0.548) e ((msnb2[j] >= 0.6) e
(msnb2[j] <= 1.0) e (snbp < snbn)) e (t[j]>= 0.49999999) e
(t[j] <= 0.50000001) então
  início
  t1[j]=0.55;
  fim

  // wits e sna normal snb alto (35)
  senão se (msna2[j] <= 0.548) e ((msnb2[j] >= 0.6) e
(msnb2[j] <= 1.0) e (snbp > snbn)) e ( t[j]>= 0.49999999) e
(t[j] <= 0.50000001) então
  início
  t1[j]=0.56;
  fim

  // wits e snb normal /sna baixo (36)
  senão se ((msna2[j] >= 0.548) e (msna2[j] <= 1.0) e
(snap < snan)) e (msnb2[j] <= 0.6) e (t[j]>= 0.49999999) e
(t[j] <= 0.50000001) então
  início
  t1[j]=0.58;
  fim

  // wits e snb normal /sna alto (37)
  senão se ((msna2[j] >= 0.548) e (msna2[j] <= 1.0) e
(snap > snan)) e (msnb2[j] <= 0.6) e (t[j]>= 0.49999999) e
(t[j] <= 0.50000001) então
  início
  t1[j]=0.59;
  fim

  //sna alto e (tendência classe II) snb baixo (3)
  senão se ((msna2[j] >= 0.889) e (snap > snan)) e
((snbp < snbn ) e (msnb2[j]>= 0.88)) e ((mwits2[j]>=0.68) e
(mwits2[j] <= 0.87) e (witsp > witsn)) então
  início
  t1[j]=0.37;
  fim

```

```

//sna alto e tendência classe III / snb alto / campo II
//hor (17)
senão se ((msna2[j] > 0.889) e (msna2[j] <= 1.0) e
(snap > snan)) e ((mwits2[j] > 0.68) e (mwits2[j] <= 1.00)
e (witsp < witsn)) e ((snbp > snbn) e (msnb2[j]> 0.8)) e
(t9[j] < 0.4) então
início
t1[j]=0.57;
fim

//sna alto quase classe II snb normal (4)
senão se ((msna2[j] > 0.889) e (msna2[j] <= 1.0) e
(snap > snan)) e ((t[j] > 0.1) e (t[j]<= 0.29999999)) e
((msnb2[j]>= 0.0) e (msnb2[j]<= 0.45)) então
início
t1[j]=0.22;
fim

//sna alto quase classe II snb baixo (5)
senão se ((msna2[j] > 0.889) e (msna2[j] <= 1.0) e
(snap > snan)) e ((t[j]<= 0.39999999) e (t[j] > 0.1)) e
((snbp < snbn ) e (msnb2[j]> 0.88) e (msnb2[j]<= 1.0))
então
início
t1[j]=0.17;
fim

//sna alto e tendência classe III campo II vertical ou
//normal (19)
senão se (msna2[j] > 0.889) e (msna2[j] <= 1.0) e
(snap > snan) e ((mwits2[j] > 0.68) e (mwits2[j] <= 1.00)
e (witsp < witsn)) e ((t9[j] > 0.6) and (t9[j] <= 1.0))
então
início
t1[j]=0.97;
fim

//sna alto e quase classe III = inconsistência (20)
senão se ((msna2[j] > 0.889) e (msna2[j] <= 1.0) e
(snap > snan)) e ((mwits2[j] > 0.68) e (mwits2[j] <= 1.00)
e (witsp < witsn)) então
início
t1[j]=0.98;
fim

```

```

//sna baixo e tendência classe II  snb baixo e campo II
//horizontal (8)
senão se ((msna2[j] >= 0.78) e (msna2[j] <= 1.0) e
(snap < snan)) e ((t[j]> 0.3) e (t[j] <= 0.499999999)) e
((snbp < snbn ) e (msnb2[j]>= 0.77)) e ((t9[j] > 0.3) e
(t9[j]< 0.4)) então
início
t1[j]=0.32;
fim

//sna baixo e tendência classe III  snb alto(7)
senão se ((msna2[j] >= 0.548) e (msna2[j] <= 1.0) e
(snap < snan)) e ((msnb2[j]>= 0.450) e (msnb2[j]<= 0.887)
e (snbp > snbn)) e (( t[j]>= 0.51) e (t[j] <= 0.699999999))
então
início
t1[j]=0.67;
fim

//sna baixo quase classe III  snb normal (8)
senão se ((msna2[j] >= 0.548) e (msna2[j] <= 1.0) e
(snap < snan)) e ((t[j]>= 0.7) e (t[j] < 0.9)) e
(msnb2[j] <= 0.49) e ((manb2[j]> 0.676) e
(manb2[j]<= 1.0)) então
início
t1[j]=0.77;
fim

//sna baixo quase classe III  snb alto (9)
senão se ((msna2[j] >= 0.548) e (msna2[j] <= 1.0) e
(snap < snan)) e (( t[j]>= 0.7) e (t[j] < 0.9)) e
((snbp > snbn) e ((msnb2[j] >= 0.67) e (msnb2[j] <= 1.0)))
e ((manb2[j]>= 0.67) e (manb2[j]<= 1.0)) então
início
t1[j]=0.82;
fim

```

```

// avaliação da mandíbula

//snb alto - tendência classe II - **campo II
//horizontal** e sna alto (4)
senão se ((msna2[j] > 0.889) e (msna2[j] <= 1.0) e
(snap > snan)) e ((t[j] >= 0.1) e (t[j]< 0.49999999)) e
((snbp > snbn) e (msnb2[j] > 0.6)) e ((t9[j] > 0.3) e
(t9[j]< 0.4)) então
início
t1[j]=0.22;
fim

//snb incons. , sna normal ou baixo, (campo II normal ou
//vertical) e tendência classe II (32)
senão se ((snap < snan) e ((msna2[j] >= 0.88) e
(msna2[j] <= 1.0))) e (( mwits2[j] > 0.68 ) e
(mwits2[j]<= 1.00) e (witsp > witsn )) e (msnb2[j]<= 1.11)
e ((t9[j] > 0.6) e (t9[j]< 0.7)) ou ((t9[j] > 0.9) e
(t9[j]< 1.00))) então
início
t1[j]=0.11;
fim

//falta informação de wits snb alto / sna baixo -
inconsistência com tendência a classe III (25)
senão se ((msna2[j] > 0.88) e (msna2[j] <= 1.0) e
(snap <= snan)) e ((snbp >= snbn ) e ((msnb2[j]> 0.8) e
(msnb2[j]<= 1.0))) e (mwits2[j]>=1.11) então
início
t1[j]=0.94;
fim

//falta informação de wits snb normal / sna normal -
inconsistência com tendência a normal (26)
senão se (msna2[j] <= 0.6) e (msnb2[j]<= 0.548) e
(mwits2[j]>=1.11) então
início
t1[j]=0.06;
fim

```

```

//falta informação de wits snb alto / sna normal -
//inconsistência com tendência a classe III (27)
  senão se (msna2[j] <= 0.6) e ((snbp >= snbn ) e
((msnb2[j]> 0.8) e (msnb2[j]<= 1.0))) e (mwits2[j]>=1.11)
então
  início
  t1[j]=0.07;
  fim

//falta informação de wits snb baixo / sna normal -
//inconsistência com tendência a classe III (29)
  senão se (msna2[j] <= 0.6) e ((snbp <= snbn ) e
((msnb2[j]> 0.8) e (msnb2[j]<= 1.0))) e (mwits2[j]>=1.11)
então
  início
  t1[j]=0.91;
  fim

//falta informação de wits snb normal / sna alto -
//inconsistência com tendência a classe II (28)
  senão se ((msna2[j] > 0.88) e (msna2[j] <= 1.0) e
(snap >= snan)) e (msnb2[j]<= 0.548) e (mwits2[j]>=1.11)
então
  início
  t1[j]=0.08;
  fim

//falta informação de wits snb normal / sna baixo -
inconsistência com tendência a classe II (30)
  senão se ((msna2[j] > 0.88) e (msna2[j] <= 1.0) e
(snap <= snan)) e (msnb2[j]<= 0.548) e (mwits2[j]>=1.11)
então
  início
  t1[j]=0.88;
  fim

//falta informação de wits: snb baixo / sna alto -
//inconsistência com tendência a classe II (24)
  senão se ((msna2[j] > 0.88) e (msna2[j] <= 1.0) e
(snap >= snan)) e ((snbp <= snbn ) e ((msnb2[j]> 0.8) e
(msnb2[j]<= 1.0))) e (mwits2[j]>=1.11) então
  início
  t1[j]=0.02;
  fim

```

```

//só informação de wits (alto) - tendência a maxila
//protruída, mandíbula retruída (classe II) (22)
senão se (msna2[j] >= 1.11) e (msnb2[j]>= 1.11) e
(( mwits2[j] > 0.68 ) e (mwits2[j] <= 1.00 ) e
(witsp > witsn)) então
início
t1[j]=0.01;
fim

//só informação de wits (baixo) - tendência a maxila
//retruída, mandíbula protruída (classe III) (23)
senão se (msna2[j] >= 1.11) e (msnb2[j]>= 1.11) e
((mwits2[j] > 0.68) e (mwits2[j] <= 1.00) e
(witsp < witsn)) então
início
t1[j]=0.93;
fim

//só informação de wits (normal)
senão se (msna2[j] >= 1.11) e (msnb2[j]>= 1.11) e
(mwits2[j] <= 0.6) então
início
t1[j]=0.04;
fim

senão //paracompleto

início
t1[j]=1.11;
fim;

fim;

```


Apêndice 4

Código do algoritmo que implementa as regras de diagnóstico da unidade II –
discrepância esquelética vertical:

Variáveis utilizadas:

t2[j] = resultante da relação entre as variáveis Se-Go e Na-Me
t3[j] = resultante da relação entre as variáveis NaANS e ANSMe
t4[j] = saída correspondente à variável napmf
t5[j] = saída correspondente à variável senap
t6[j] = saída correspondente à variável senafop
t7[j] = saída correspondente à variável senamp
t8[j] = saída correspondente a composição dos planos senap, senafop e senamp
t9[j] = saída correspondente à unidade II
crenc9 = grau de evidência relacionado à relação SE-Go / Na-Me
nansp = variável NaANS do paciente
nansn = variável NaANS padrão
ansmep = variável ANSMe do paciente
ansmen = variável ANSMe padrão
napmf_n = variável napmf padrão
napmf_p = variável napmf do paciente
mnapmf2[j] = matriz com os graus de evidência de napmf
senapp = variável SeNa/PP do paciente
senapn = variável SeNa/PP padrão
msenp2[j] = matriz com os graus de evidência de SeNa/PP
senafop = variável SeNa/PO do paciente
senafon = variável SeNa/PO padrão
msenafo2[j] = matriz com os graus de evidência de SeNa/PO
senampp = variável SeNa/PM do paciente
senampn = variável SeNa/PM padrão
msenamp2[j] = matriz com os graus de evidência de SeNa/PM

Código:

```
//unidade II - vertical

    início
//relação se-go/na-me
se (crenc9 <= -0.1) então
início
t2[j]=0.33;//horizontal
fim

senão se (crenc9 > -0.1) e (crenc9 <= 0.04) então
início
t2[j]=0.66;//normal
fim

senão se (crenc9 > 0.04) e (crenc9 <= 1.0) então
início
t2[j]=0.99;//vertical
fim

senão
início
t2[j]=1.11;//inconsistente
fim
fim;

//relação nans/ansme
início

se (nansp > nansn*1.13) ou (ansmep > ansmen*1.13) então
início
t3[j]=0.33;//horizontal
fim

senão se ((nansp >= nansn*0.87) e (nansp <= nansn*1.13))
ou((ansmep >= ansmen*0.87) e (ansmep <= ansmen*1.13)) então
início
t3[j]=0.66;//normal
fim
```

```

    senão se (nansp < nansn*0.87) ou (ansmep < ansmen*0.87)
então
    início
    t3[j]=0.99;//vertical
    fim
fim;

início
//eixo y
se (napmfp < napmfn) e ((mnapmf2[j] >= 0.6) e
(mnapmf2[j]<= 1.0)) então
    início
    t4[j]=0.33;//horizontal
    fim

    senão se (mnapmf2[j] < 0.6) então
    início
    t4[j]=0.66;//normal
    fim

    senão se (napmfp > napmfn) e ((mnapmf2[j] >= 0.6) e
(mnapmf2[j] <= 1.0)) então
    início
    t4[j]=0.99;//vertical
    fim

    senão
    início
    t4[j]=1.11;//inconsistente
    fim
fim;

início
//senapp
se (senapp < senapn) e ((msenap2[j] >= 0.6) e
(msenap2[j] <= 1.0)) então
    início
    t5[j]=0.33;//horizontal
    fim

    senão se (msenap2[j] < 0.6) então
    início
    t5[j]=0.66;//normal
    fim

```

```

    senão se (senapp > senapn) e ((msenap2[j] >= 0.6) e
(msenap2[j] <= 1.0)) então
    início
    t5[j]=0.99;//vertical
    fim

senão
    início
    t5[j]=1.11;//inconsistente
    fim
fim;
início

    //senafop
    se (senafop < senafon) e ((msenafo2[j] >= 0.6) e
(msenaf2[j] <= 1.0)) então
    início
    t6[j]=0.33;//horizontal
    fim

    senão se (msenafo2[j] < 0.6) então
    início
    t6[j]=0.66;//normal
    fim

    senão se (senafop > senafon) e ((msenafo2[j] >= 0.6) e
(msenaf2[j] <= 1.0)) então
    início
    t6[j]=0.99;//vertical
    fim

    senão
    início
    t6[j]=1.11;//inconsistente
    fim
fim;

    início
    //senamp
se (senampp < senampn) e ((msenamp2[j] >= 0.6) e
(msenamp2[j] <= 1.0)) então
    início
    t7[j]=0.33;//horizontal
    fim

```

```

senão se ( msenamp2[j] < 0.6) então
  início
  t7[j]=0.66;//normal
  fim

  senão se (senampp > senampn) e ((msenamp2[j] >= 0.6) e
(msenamp2[j] <= 1.0)) então
  início
  t7[j]=0.99;//vertical
  fim

  senão
  início
  t7[j]=1.11;//inconsistente
  fim
fim;

//composição do grau de evidência dos planos
início
  //normal
  se ((t5[j]>= 0.60) e (t5[j] <= 0.70)) e ((t6[j]>= 0.60) e
(t6[j] <= 0.70)) e ((t7[j]>= 0.60) e (t7[j] <= 0.70)) então
  início
  t8[j]=0.66;
  fim

  senão se ((t5[j]>= 0.30) e (t5[j] <= 0.40)) e
((t6[j]>= 0.60) e (t6[j] <= 0.70)) e ((t7[j]>= 0.60) e
(t7[j] <= 0.70)) então
  início
  t8[j]=0.66;
  fim

  senão se ((t5[j]>= 0.90) e (t5[j] <= 1.00)) e
((t6[j]>= 0.60) e (t6[j] <= 0.70)) e
((t7[j]>= 0.60) e (t7[j] <= 0.70)) então
  início
  t8[j]=0.66;
  fim

```

```
senão se ((t5[j]>= 0.60) e (t5[j] <= 0.70)) e
((t6[j]>= 0.30) e (t6[j] <= 0.40)) e ((t7[j]>= 0.60) e
(t7[j] <= 0.70)) então
  início
  t8[j]=0.66;
  fim
```

```
senão se ((t5[j]>= 0.60) e (t5[j] <= 0.70)) e
((t6[j]>= 0.90) e (t6[j] <= 1.00)) e ((t7[j]>= 0.60) e
(t7[j] <= 0.70)) então
  início
  t8[j]=0.66;
  fim
```

```
senão se ((t5[j]>= 0.60) e (t5[j] <= 0.70)) e
((t6[j]>= 0.60) e (t6[j] <= 0.70)) e ((t7[j]>= 0.30) e
(t7[j] <= 0.40)) então
  início
  t8[j]=0.66;
  fim
```

```
senão se ((t5[j]>= 0.60) e (t5[j] <= 0.70)) e
((t6[j]>= 0.60) e (t6[j] <= 0.70)) e ((t7[j]>= 0.90) e
(t7[j] <= 1.00)) então
  início
  t8[j]=0.66;
  fim
```

```
//horizontal
```

```
senão se ((t5[j]>= 0.30) e (t5[j] <= 0.40)) e
((t6[j]>= 0.30) e (t6[j] <= 0.40)) e ((t7[j]>= 0.30) e
(t7[j] <= 0.40)) então
  início
  t8[j]=0.33;
  fim
```

```
senão se ((t5[j]>= 0.30) e (t5[j] <= 0.40)) e
((t6[j]>= 0.30) e (t6[j] <= 0.40)) e ((t7[j]>= 0.60) e
(t7[j] <= 0.70)) então
  início
  t8[j]=0.33;
  fim
```

```
senão se ((t5[j]>= 0.30) e (t5[j] <= 0.40)) e
  ((t6[j]>= 0.30) e (t6[j] <= 0.40)) e ((t7[j]>= 0.90) e
(t7[j] <= 1.00)) então
  início
  t8[j]=0.33;
  fim
```

```
senão se ((t5[j]>= 0.30) e (t5[j] <= 0.40)) e
  ((t6[j]>= 0.60) e (t6[j] <= 0.70)) e ((t7[j]>= 0.30) e
(t7[j] <= 0.40)) então
  início
  t8[j]=0.33;
  fim
```

```
senão se ((t5[j]>= 0.30) e (t5[j] <= 0.40)) e
  ((t6[j]>= 0.90) e (t6[j] <= 1.00)) e ((t7[j]>= 0.30) e
(t7[j] <= 0.40)) então
  início
  t8[j]=0.33;
  fim
```

```
senão se ((t5[j]>= 0.60) e (t5[j] <= 0.70)) e
  ((t6[j]>= 0.30) e (t6[j] <= 0.40)) e ((t7[j]>= 0.30) e
(t7[j] <= 0.40)) então
  início
  t8[j]=0.33;
  fim
```

```
senão se ((t5[j]>= 0.90) e (t5[j] <= 1.00)) e
  ((t6[j]>= 0.30) e (t6[j] <= 0.40)) e ((t7[j]>= 0.30) e
(t7[j] <= 0.40)) então
  início
  t8[j]=0.33;
  fim
```

```
//vertical
```

```
senão se ((t5[j]>= 0.90) e (t5[j] <= 1.00)) e
  ((t6[j]>= 0.90) e (t6[j] <= 1.00)) e ((t7[j]>= 0.90) e
(t7[j] <= 1.00)) então
  início
  t8[j]=0.99;
  fim
```

```
senão se ((t5[j]>= 0.90) e (t5[j] <= 1.00)) e
((t6[j]>= 0.90) e (t6[j] <= 1.00)) e ((t7[j]>= 0.30) e
(t7[j] <= 0.40)) então
início
t8[j]=0.99;
fim
```

```
senão se ((t5[j]>= 0.90) e (t5[j] <= 1.00)) e
((t6[j]>= 0.90) e (t6[j] <= 1.00)) e ((t7[j]>= 0.60) e
(t7[j] <= 0.70)) então
início
t8[j]=0.99;
fim
```

```
senão se ((t5[j]>= 0.90) e (t5[j] <= 1.00)) e
((t6[j]>= 0.60) e (t6[j] <= 0.70)) e ((t7[j]>= 0.90) e
(t7[j] <= 1.00)) então
início
t8[j]=0.99;
fim
```

```
senão se ((t5[j]>= 0.90) e (t5[j] <= 1.00)) e
((t6[j]>= 0.30) e (t6[j] <= 0.40)) e ((t7[j]>= 0.90) e
(t7[j] <= 1.00)) então
início
t8[j]=0.99;
fim
```

```
senão se ((t5[j]>= 0.60) e (t5[j] <= 0.70)) e
((t6[j]>= 0.90) e (t6[j] <= 1.00)) e ((t7[j]>= 0.90) e
(t7[j] <= 1.00)) então
início
t8[j]=0.99;
fim
```

```
senão se ((t5[j]>= 0.30) e (t5[j] <= 0.40)) e
((t6[j]>= 0.90) e (t6[j] <= 1.00)) e ((t7[j]>= 0.90) e
(t7[j] <= 1.00)) então
início
t8[j]=0.99;
fim
```

```
//inconsistente
```



```
senão se ((t5[j]>= 0.30) e (t5[j] <= 0.40)) e
((t6[j]>= 0.60) e (t6[j] <= 0.70)) e ((t7[j]>= 0.90) e
(t7[j] <= 1.00)) então
início
t8[j]=1.11;
fim
```

```
senão se ((t5[j]>= 0.30) e (t5[j] <= 0.40)) e
((t6[j]>= 0.90) e (t6[j] <= 1.00)) e((t7[j]>= 0.60) e
(t7[j] <= 0.70)) então
início
t8[j]=1.11;
fim
```

```
senão se ((t5[j]>= 0.60) e (t5[j] <= 0.70)) e
((t6[j]>= 0.90) e (t6[j] <= 1.00)) e((t7[j]>= 0.30) e
(t7[j] <= 0.40)) então
início
t8[j]=1.11;
fim
```

```
senão se ((t5[j]>= 0.60) e (t5[j] <= 0.70)) e
((t6[j]>= 0.30) e (t6[j] <= 0.40)) e ((t7[j]>= 0.90) e
(t7[j] <= 1.00)) então
início
t8[j]=1.11;
fim
```

```
senão se ((t5[j]>= 0.90) e (t5[j] <= 1.00)) e
((t6[j]>= 0.30) e (t6[j] <= 0.40)) e ((t7[j]>= 0.60) e
(t7[j] <= 0.70)) então
início
t8[j]=1.11;
fim
```

```
senão se ((t5[j]>= 0.90) e (t5[j] <= 1.00)) e
((t6[j]>= 0.60) e (t6[j] <= 0.70)) e ((t7[j]>= 0.30) e
(t7[j] <= 0.40)) então
início
t8[j]=1.11;
fim
```

```

senão se (t5[j]>= 1.11) e (t6[j]>= 1.11) então
início
t8[j]=1.11;
fim

senão se (t5[j]>= 1.11) e (t7[j]>= 1.11) então
início
t8[j]=1.11;
fim

senão se (t7[j]>= 1.11) e (t6[j]>= 1.11) então
início
t8[j]=1.11;
fim

fim;

//composição da unidade II
início
    //normal
se ((t2[j]>= 0.60) e (t2[j] <= 0.70)) e ((t4[j]>= 0.60) e
(t4[j] <= 0.70)) e ((t8[j]>= 0.60) e (t8[j] <= 0.70)) então
    início
    t9[j]=0.66;
    fim

senão se ((t2[j]>= 0.30) e (t2[j] <= 0.40)) e
((t4[j]>= 0.60) e (t4[j] <= 0.70)) e ((t8[j]>= 0.60) e
(t8[j] <= 0.70)) então
    início
    t9[j]=0.66;
    fim

senão se ((t2[j]>= 0.90) e (t2[j] <= 1.00)) e
((t4[j]>= 0.60) e (t4[j] <= 0.70)) e ((t8[j]>= 0.60) e
(t8[j] <= 0.70)) então
    início
    t9[j]=0.66;
    fim

```

```
senão se ((t2[j]>= 0.60) e (t2[j] <= 0.70)) e
((t4[j]>= 0.30) e (t4[j] <= 0.40)) e ((t8[j]>= 0.60) e
(t8[j] <= 0.70)) então
  início
  t9[j]=0.66;
  fim
```

```
senão se ((t2[j]>= 0.60) e (t2[j] <= 0.70)) e
((t4[j]>= 0.90) e (t4[j] <= 1.00)) e ((t8[j]>= 0.60) e
(t8[j] <= 0.70)) então
  início
  t9[j]=0.66;
  fim
```

```
senão se ((t2[j]>= 0.60) e (t2[j] <= 0.70)) e
((t4[j]>= 0.60) e (t4[j] <= 0.70)) e ((t8[j]>= 0.30) e
(t8[j] <= 0.40)) então
  início
  t9[j]=0.66;
  fim
```

```
senão se ((t2[j]>= 0.60) e (t2[j] <= 0.70)) e
((t4[j]>= 0.60) e (t4[j] <= 0.70)) e ((t8[j]>= 0.90) e
(t8[j] <= 1.00)) então
  início
  t9[j]=0.66;
  fim
```

```
senão se ((t2[j]>= 0.60) e (t2[j] <= 0.70)) e
((t4[j]>= 0.60) e (t4[j] <= 0.70)) e (t8[j] >= 1.11) então
  início
  t9[j]=0.66;
  fim
```

```
//horizontal
```

```
senão se ((t2[j]>= 0.30) e (t2[j] <= 0.40)) e
((t4[j]>= 0.30) e (t4[j] <= 0.40)) e ((t8[j]>= 0.30) e
(t8[j] <= 0.40)) então
  início
  t9[j]=0.33;
  fim
```

```
senão se ((t2[j]>= 0.30) e (t2[j] <= 0.40)) e
((t4[j]>= 0.30) e (t4[j] <= 0.40)) e ((t8[j]>= 0.60) e
(t8[j] <= 0.70)) então
início
t9[j]=0.33;
fim
```

```
senão se ((t2[j]>= 0.30) e (t2[j] <= 0.40)) e
((t4[j]>= 0.30) e (t4[j] <= 0.40)) e ((t8[j]>= 0.90) e
(t8[j] <= 1.00)) então
início
t9[j]=0.33;
fim
```

```
senão se ((t2[j]>= 0.30) e (t2[j] <= 0.40)) e
((t4[j]>= 0.60) e (t4[j] <= 0.70)) e ((t8[j]>= 0.30) e
(t8[j] <= 0.40)) então
início
t9[j]=0.33;
fim
```

```
senão se ((t2[j]>= 0.30) e (t2[j] <= 0.40)) e
((t4[j]>= 0.90) e (t4[j] <= 1.00)) e ((t8[j]>= 0.30) e
(t8[j] <= 0.40)) então
início
t9[j]=0.33;
fim
```

```
senão se ((t2[j]>= 0.60) e (t2[j] <= 0.70)) e
((t4[j]>= 0.30) e (t4[j] <= 0.40)) e ((t8[j]>= 0.30) e
(t8[j] <= 0.40)) então
início
t9[j]=0.33;
fim
```

```
senão se ((t2[j]>= 0.90) e (t2[j] <= 1.00)) e
((t4[j]>= 0.30) e (t4[j] <= 0.40)) e ((t8[j]>= 0.30) e
(t8[j] <= 0.40)) então
início
t9[j]=0.33;
fim
```

```

senão se ((t2[j]>= 0.30) e (t2[j] <= 0.40)) e
((t4[j]>= 0.30) e (t4[j] <= 0.40)) e (t8[j] >= 1.11)
então
início
t9[j]=0.33;
fim

//vertical

senão se ((t2[j]>= 0.90) e (t2[j] <= 1.00)) e
((t4[j]>= 0.90) e (t4[j] <= 1.00)) e ((t8[j]>= 0.90) e
(t8[j] <= 1.00)) então
início
t9[j]=0.99;
fim

senão se ((t2[j]>= 0.90) e (t2[j] <= 1.00)) e
((t4[j]>= 0.90) e (t4[j] <= 1.00)) e((t8[j]>= 0.30) e
(t8[j] <= 0.40)) então
início
t9[j]=0.99;
fim

senão se ((t2[j]>= 0.90) e (t2[j] <= 1.00)) e
((t4[j]>= 0.90) e (t4[j] <= 1.00)) e ((t8[j]>= 0.60) e
(t8[j] <= 0.70)) então
início
t9[j]=0.99;
fim

senão se ((t2[j]>= 0.90) e (t2[j] <= 1.00)) e
((t4[j]>= 0.60) e (t4[j] <= 0.70)) e ((t8[j]>= 0.90) e
(t8[j] <= 1.00)) então
início
t9[j]=0.99;
fim

senão se ((t2[j]>= 0.90) e (t2[j] <= 1.00)) e
((t4[j]>= 0.30) e (t4[j] <= 0.40)) e ((t8[j]>= 0.90) e
(t8[j] <= 1.00)) então
início
t9[j]=0.99;
fim

```

```
senão se ((t2[j]>= 0.60) e (t2[j] <= 0.70)) e
((t4[j]>= 0.90) e (t4[j] <= 1.00)) e ((t8[j]>= 0.90) e
(t8[j] <= 1.00)) então
início
t9[j]=0.99;
fim
```

```
senão se ((t2[j]>= 0.30) e (t2[j] <= 0.40)) e
((t4[j]>= 0.90) e (t4[j] <= 1.00)) e ((t8[j]>= 0.90) e
(t8[j] <= 1.00)) então
início
t9[j]=0.99;
fim
```

```
senão se (( t2[j]>= 0.90) e (t2[j] <= 1.00)) e
((t4[j]>= 0.90) e (t4[j] <= 1.00)) e (t8[j] >= 1.11) então
início
t9[j]=0.99;
fim
```

```
//inconsistente (prevalecendo eixo y)
```

```
senão se ((t2[j]>= 0.30) e (t2[j] <= 0.40)) e
((t4[j]>= 0.60) e (t4[j] <= 0.70)) e ((t8[j]>= 0.90) e
(t8[j] <= 1.00)) então
início
t9[j]=0.66;
fim
```

```
senão se ((t2[j]>= 0.30) e (t2[j] <= 0.40)) e
((t4[j]>= 0.90) e (t4[j] <= 1.00)) e ((t8[j]>= 0.60) e
(t8[j] <= 0.70)) então
início
t9[j]=0.99;
fim
```

```
senão se ((t2[j]>= 0.30) e (t2[j] <= 0.40)) e
((t4[j]>= 0.60) e (t4[j] <= 0.70)) e (t8[j] >= 1.11) então
início
t9[j]=0.66;
fim
```

```
senão se ((t2[j]>= 0.60) e (t2[j] <= 0.70)) e
((t4[j]>= 0.90) e (t4[j] <= 1.00)) e ((t8[j]>= 0.30) e
(t8[j] <= 0.40)) então
início
t9[j]=0.99;
fim
```

```
senão se ((t2[j]>= 0.60) e (t2[j] <= 0.70)) e
((t4[j]>= 0.30) e (t4[j] <= 0.40)) e
((t8[j]>= 0.90) e (t8[j] <= 1.00)) então
início
t9[j]=0.33;
fim
```

```
senão se ((t2[j]>= 0.60) e (t2[j] <= 0.70)) e
((t4[j]>= 0.30) e (t4[j] <= 0.40)) e (t8[j] >= 1.11) então
início
t9[j]=0.33;
fim
```

```
senão se ((t2[j]>= 0.90) e (t2[j] <= 1.00)) e
((t4[j]>= 0.30) e (t4[j] <= 0.40)) e ((t8[j]>= 0.60) e
(t8[j] <= 0.70)) então
início
t9[j]=0.33;
fim
```

```
senão se ((t2[j]>= 0.90) e (t2[j] <= 1.00)) e
((t4[j]>= 0.60) e (t4[j] <= 0.70)) e ((t8[j]>= 0.30) e
(t8[j] <= 0.40)) então
início
t9[j]=0.66;
fim
```

```
senão se ((t2[j]>= 0.90) e (t2[j] <= 1.00)) e
((t4[j]>= 0.60) e (t4[j] <= 0.70)) e (t8[j] >= 1.11) então
início
t9[j]=0.66;
fim
```

```
senão se ((t2[j]>= 1.11) ou (t4[j]>= 1.11)) e
(t8[j] >= 1.11) então
início
t9[j]=1.11;
fim
```

```
senão se ((t2[j]>= 1.11) e (t4[j]>= 1.11)) então
início
t9[j]=t8[j];
fim

senão
início
    t9[j]=1.11;
fim

fim;
```


Apêndice 5

Código do algoritmo que implementa as regras de diagnóstico da unidade III – alterações dentárias

//implementação do campo III - alterações dentárias

Variáveis utilizadas:

u1snp = variável U1.SN do paciente
u1ppp = variável U1.PP do paciente
u1nap = variável U1-Na do paciente
u1l1p = variável U1.L1 do paciente
l1gomep = variável L1.GoMe do paciente
l1nbp = variável L1.NB do paciente
l1apgp = variável L1.APg do paciente
l1apg1p = variável L1-APg do paciente
l1nb1p = variável L1-NB do paciente
mu1na2[j] = matriz com os graus de evidência da variável U1.Na
mu1sn2[j] = matriz com os graus de evidência da variável U1.SN
mu1pp2[j] = matriz com os graus de evidência da variável U1.PP
mu1na2[j] = matriz com os graus de evidência da variável U1.
ml1apg2[j] = matriz com os graus de evidência da variável L1.APg
ml1apg12[j] = matriz com os graus de evidência da variável L1-APg
ml1nb2[j] = matriz com os graus de evidência da variável L1.NB
ml1nb12[j] = matriz com os graus de evidência da variável L1-NB
mu1l12[j] = matriz com os graus de evidência da variável U1.L1
ml1gome2[j] = matriz com os graus de evidência da variável L1.GoMe
t10[j] = representa o grau de evidência resultante da conjugação das variáveis U1.SN e U1.Na
t11[j] = representa o grau de evidência resultante da conjugação das variáveis L1.APg e L1-APg
t12[j] = representa o grau de evidência resultante da conjugação das variáveis L1.NB e L1-NB
t13[j] = representa o grau de evidência resultante da conjugação da variável L1.GoMe, t11[j] e t12[j] (l1gome + apg + nb)

Código:

```
//conjugando ulna e ulsn
se (msna2[j] <= 0.548) então

início
//ulpp normal

//normais
se (mulsn2[j] <= 0.6) e (mulna2[j] <= 0.6) e
(mulpp2[j] <= 0.6) então
início
t10[j] = 0.66; //normal
fim

//ulsn vestibularizado - ulna normal
senão se ((ulsnp > ulsnn) e ((mulsn2[j] > 0.6) e
(mulsn2[j] <= 1.0))) e (mulna2[j] <= 0.6) e
(mulpp2[j] <= 0.6) então
início
t10[j] = 0.66;//normal
fim

//ulsn lingualizado - ulna normal
senão se ((ulsnp < ulsnn) e ((mulsn2[j] > 0.6) e
(mulsn2[j] <= 1.0))) e (mulna2[j] <= 0.6) e
(mulpp2[j] <= 0.6) então
início
t10[j] = 0.66; //normal
fim

//ulsn vestibularizado - ulna vestibularizado
senão se ((ulsnp > ulsnn) e ((mulsn2[j] > 0.6) e (mulsn2[j]
<= 1.0))) e ((ulnap > ulnan) e ((mulna2[j] > 0.6) e
(mulna2[j] <= 1.0))) e (mulpp2[j] <= 0.6) então
início
t10[j] = 0.92;//tende vestibularizado
fim
```

```
//ulsn vestibularizado - ulna lingualizado
senão se ((ulsnp > ulsnn) and ((mulsn2[j] > 0.6) e
(mulsn2[j] <= 1.0))) e ((ulnap < ulnan) e
((mulna2[j] > 0.6 ) e (mulna2[j] <= 1.0 ))) e
(mulpp2[j] <= 0.6) então
início
t10[j] = 0.66; //normal
fim
```

```
//ulsn normal - ulna lingualizado
senão se (mulsn2[j] <= 0.6) e ((ulnap < ulnan) e
((mulna2[j] > 0.6) e (mulna2[j] <= 1.0 ))) e
(mulpp2[j] <= 0.6) então
início
t10[j] = 0.66; //normal
fim
```

```
//ulsn normal - ulna vestibularizado
senão se ( mulsn2[j] <= 0.6 ) e ((ulnap > ulnan) e
((mulna2[j] > 0.6) e(mulna2[j] <= 1.0 ))) e
(mulpp2[j] <= 0.6) então
início
t10[j] = 0.66;//normal
fim
```

```
//ulsn lingualizado - ulna lingualizado
senão se ((ulsnp < ulsnn) e ((mulsn2[j] > 0.6) e
(mulsn2[j] <= 1.0))) e ((ulnap < ulnan) e
((mulna2[j] > 0.6) e (mulna2[j] <= 1.0))) e
(mulpp2[j] <= 0.6) então
início
t10[j] = 0.38; //tende lingualizado
fim
```

```
//ulsn lingualizado - ulna vestibularizado
senão se ((ulsnp < ulsnn) e ((mulsn2[j] > 0.6) e
(mulsn2[j] <= 1.0 ))) e ((ulnap > ulnan) e
((mulna2[j] > 0.6) e (mulna2[j] <= 1.0))) e
(mulpp2[j] <= 0.6 ) então
início
t10[j] = 0.38; //tende lingualizado
fim
```

```

//ulpp lingualizado

    //normais
senão se (mulsn2[j] <= 0.6) e (mulna2[j] <= 0.6) e
((ulppp < ulppn) e ((mulpp2[j] > 0.6) e
(mulpp2[j] <= 1.0))) então
início
t10[j] = 0.35; //quase seg. lingualizado
fim

    //ulsn vestibularizado - ulna normal
senão se ((ulsnp > ulsnn) e ((mulsn2[j] > 0.6) e
(mulsn2[j] <= 1.0))) e (mulna2[j] <= 0.6) e
((ulppp < ulppn) e ((mulpp2[j] > 0.6) e
(mulpp2[j] <= 1.0))) então
início
t10[j] = 1.11; //inconsistente
fim

    //ulsn lingualizado - ulna normal
senão se ((ulsnp < ulsnn) e ((mulsn2[j] > 0.6) e
(mulsn2[j] <= 1.0))) e (mulna2[j] <= 0.6) e
((ulppp < ulppn) e ((mulpp2[j] > 0.6) e
(mulpp2[j] <= 1.0))) então
início
t10[j] = 0.35; //quase seg. lingualizado
fim

    //ulsn vestibularizado - ulna vestibularizado
senão se ((ulsnp > ulsnn) e ((mulsn2[j] > 0.6) e
(mulsn2[j] <= 1.0))) e ((ulnap > ulnan) e
((mulna2[j] > 0.6) e (mulna2[j] <= 1.0))) e
((ulppp < ulppn) e ((mulpp2[j] > 0.6) e
(mulpp2[j] <= 1.0))) então
início
t10[j] = 0.38; //inconsistente, prevalece U1.PP
fim

```

```
    //ulsn vestibularizado - ulna lingualizado
senão se ((ulsnp > ulsnn) e ((mulsn2[j] > 0.6) e
(mulsn2[j] <= 1.0))) e ((ulnap < ulnan) e
((mulna2[j] > 0.6) e (mulna2[j] <= 1.0))) e
((ulppp < ulppn) e ((mulpp2[j] > 0.6) e
(mulpp2[j] <= 1.0))) então
início
t10[j] = 0.38; //tende lingualizado
fim
```

```
    //ulsn normal - ulna lingualizado
senão se (mulsn2[j] <= 0.6) e ((ulnap < ulnan) e
((mulna2[j] > 0.6) e
(mulna2[j] <= 1.0))) e ((ulppp < ulppn) e
((mulpp2[j] > 0.6) e (mulpp2[j] <= 1.0))) então
início
t10[j] = 0.35; // quase seg. lingualizado
fim
```

```
    //ulsn normal - ulna vestibularizado
senão se (mulsn2[j] <= 0.6) e ((ulnap > ulnan) e
(( mulna2[j] > 0.6 ) e (mulna2[j] <= 1.0))) e
((ulppp < ulppn) e ((mulpp2[j] > 0.6) e
(mulpp2[j] <= 1.0 ))) então
início
t10[j] = 0.38; //inconsistente, prevelece U1.PP
fim
```

```
    //ulsn lingualizado - ulna lingualizado
senão se ((ulsnp < ulsnn) e ((mulsn2[j] > 0.6) e
(mulsn2[j] <= 1.0))) e ((ulnap < ulnan) e
((mulna2[j] > 0.6) e (mulna2[j] <= 1.0))) e
((ulppp < ulppn) e ((mulpp2[j] > 0.6) e
(mulpp2[j] <= 1.0))) então
início
t10[j] = 0.33; // lingualizado
fim
```

```

//ulsn lingualizado - ulna vestibularizado
senão se ((ulsnp < ulsnn) e ((mulsn2[j] > 0.6) e
(mulsn2[j] <= 1.0))) e ((ulnap > ulnan) e
((mulna2[j] > 0.6) e (mulna2[j] <= 1.0))) e
((ulppp < ulppn) e ((mulpp2[j] > 0.6) e
(mulpp2[j] <= 1.0))) então
início
t10[j] = 0.33; // lingualizado
fim

//ulpp vestibularizado

//normais
senão se (mulsn2[j] <= 0.6) e (mulna2[j] <= 0.6) e
((ulppp > ulppn) e ((mulpp2[j] > 0.6) e
(mulpp2[j] <= 1.0))) então
início
t10[j] = 0.96; //quase seg. vestibularizado
fim

//ulsn vestibularizado - ulna normal
senão se ((ulsnp > ulsnn) e ((mulsn2[j] > 0.6) e
(mulsn2[j] <= 1.0))) e (mulna2[j] <= 0.6) e
((ulppp > ulppn) e ((mulpp2[j] > 0.6) e (mulpp2[j] <=
1.0))) então
início
t10[j] = 0.96; //quase seg. vestibularizado
fim

//ulsn lingualizado - ulna normal
senão se ((ulsnp < ulsnn) e ((mulsn2[j] > 0.6) e
(mulsn2[j] <= 1.0))) e (mulna2[j] <= 0.6) e
((ulppp > ulppn) e ((mulpp2[j] > 0.6)
(mulpp2[j] <= 1.0))) então
início
t10[j]:=0.92; //inconsistente, segue U1.PP
fim

```

```
    //ulsn vestibularizado - ulna vestibularizado
senão se ((ulsnp > ulsnn) e ((mulsn2[j] > 0.6) e
(mulsn2[j] <= 1.0))) e ((ulnap > ulnan) e
((mulna2[j] > 0.6) e (mulna2[j] <= 1.0))) e
((ulppp > ulppn) e ((mulpp2[j] > 0.6) e
(mulpp2[j] <= 1.0))) então
início
t10[j] = 0.99; //vestibularizado
fim
```

```
    //ulsn vestibularizado - ulna lingualizado
senão se ((ulsnp > ulsnn) e ((mulsn2[j] > 0.6) e
(mulsn2[j] <= 1.0))) e ((ulnap < ulnan) e
((mulna2[j] > 0.6) e (mulna2[j] <= 1.0))) e
((ulppp > ulppn) e ((mulpp2[j] > 0.6) e
(mulpp2[j] <= 1.0))) então
início
t10[j] = 0.92; //tende vestibularizado
fim
```

```
    //ulsn normal - ulna lingualizado
senão se (mulsn2[j] <= 0.6) e
((lnap < ulnan) e ((mulna2[j] > 0.6) e
(mulna2[j] <= 1.0))) e ((ulppp > ulppn) e
((mulpp2[j] > 0.6) e (mulpp2[j] <= 1.0))) então
início
t10[j] = 0.92; // inconsistente, segue U1.PP
fim
```

```
    //ulsn normal - ulna vestibularizado
senão se (mulsn2[j] <= 0.6) e ((ulnap > ulnan) e
((mulna2[j] > 0.6) e (mulna2[j]<= 1.0))) e ((ulppp > ulppn)
e ((mulpp2[j] > 0.6) e (mulpp2[j]<= 1.0))) então
início
t10[j] = 0.96; //quase seg. vestibularizado
fim
```

```
    //ulsn lingualizado - ulna lingualizado
senão se ((ulsnp < ulsnn) e ((mulsn2[j] > 0.6) e
(mulsn2[j] <= 1.0))) e ((ulnap < ulnan) e
((mulna2[j] > 0.6) e (mulna2[j] <= 1.0))) e
((ulppp > ulppn) e ((mulpp2[j] > 0.6) e
(mulpp2[j] <= 1.0))) então
início
t10[j] = 0.92; // inconsistente, segue U1.PP
fim
```

```
    //ulsn lingualizado - ulna vestibularizado
senão se ((ulsnp < ulsnn) e ((mulsn2[j] > 0.6) e
(mulsn2[j] <= 1.0))) e ((ulnap > ulnan) e
((mulna2[j] > 0.6) e (mulna2[j] <= 1.0))) e
((ulppp > ulppn) e ((mulpp2[j] > 0.6) e
(mulpp2[j] <= 1.0))) então
início
t10[j] = 0.92; // inconsistente, segue U1.PP
fim
```

```
senão se (mulsn2[j] >= 1.11) e (mulna2[j] >= 1.11) e
(mulpp2[j] >= 1.11) então
início
t10[j] = 1.11; // inconsistente
fim
```

```
    //considerando só ulpp (sna alto ou baixo)
```

```
    senão
    início
```

```
    //lingualizado
se ((ulppp < ulppn) e ((mulpp2[j] > 0.6) e
(mulpp2[j] <= 1.0))) então
início
t10[j] = 0.33;
fim
```

```
    //vestibularizado
senão se ((ulppp > ulppn) e ((mulpp2[j] > 0.6) e
(mulpp2[j] <= 1.0))) então
início
t10[j] = 0.99;
fim
```



```

//normal
senão se (mulpp2[j] <= 0.6) então
início
t10[j] = 0.66;
fim

senão se (mulsn2[j] >= 1.11) e (mulna2[j] >= 1.11) e
(mulpp2[j] >= 1.11) então
início
t10[j] = 1.11;
fim;

fim

fim;

//INCISIVOS INFERIORES

início

//conjugando llapg e llapg1
se (msnb2[j] <= 0.548) então

início

início
//normais
se (mllapg2[j] <= 0.6) e (mllapg12[j] <= 0.6) então
início
t11[j] = 0.66; //normal
fim

//llapg vestibularizado - llapg1 normal
senão se ((llapgp > llapgn) e ((mllapg2[j] > 0.6) e
(mllapg2[j] <= 1.0)))
e (mllapg12[j] <= 0.6) então
início
t11[j] = 0.96; //tende vestibularizado
fim

```

```
        //llapg lingualizado - llapg1 normal
senão se ((llapgp < llapgn) e ((mllapg2[j] > 0.6) e
(mllapg2[j] <= 1.0)))
e (mllapg12[j] <= 0.6) então
início
t11[j] = 0.36; //tende lingualizado
fim
```

```
        //llapg vestibularizado - llapg1 vestibularizado
senão se ((llapgp > llapgn) e ((mllapg2[j] > 0.6) e
(mllapg2[j] <= 1.0))) e ((llapgp > llapgn) e
((mllapg12[j] > 0.6) e (mllapg12[j] <= 1.0))) então
início
t11[j] = 0.99; // vestibularizado
fim
```

```
        //llapg vestibularizado - llapg1 lingualizado
senão se ((llapgp > llapgn) e ((mllapg2[j] > 0.6) e
(mllapg2[j] <= 1.0))) e ((llapgp < llapgn) e
((mllapg12[j] > 0.6) e (mllapg12[j] <= 1.0))) então
início
t11[j] = 1.11; // inconsistente
fim
```

```
        //llapg normal - llapg1 lingualizado
senão se (mllapg2[j] <= 0.6) e ((llapgp < llapgn) e
((mllapg12[j] > 0.6) e (mllapg12[j] <= 1.0))) então
início
t11[j] = 0.36; // tende lingualizado
fim
```

```
        //llapg normal - llapg1 vestibularizado
senão se (mllapg2[j] <= 0.6) e ((llapgp > llapgn) e
((mllapg12[j] > 0.6) e (mllapg12[j] <= 1.0 ))) então
início
t11[j] = 0.96; // tende vestibularizado
fim
```

```

        //llapg lingualizado - llapg1 lingualizado
senão se ((llapgp < llapgn) e ((mllapg2[j] > 0.6) e
(mllapg2[j] <= 1.0))) e ((llapgp < llapgn) e
((mllapg12[j] > 0.6) e (mllapg12[j] <= 1.0))) então
início
t11[j] = 0.33; // lingualizado
fim

        //llapg lingualizado - llapg1 vestibularizado
senão se ((llapgp < llapgn) e ((mllapg2[j] > 0.6) e
(mllapg2[j] <= 1.0))) e ((llapgp > llapgn) e
((mllapg12[j] > 0.6) e (mllapg12[j] <= 1.0 ))) então
início
t11[j] = 1.11; // lingualizado
fim

senão se (mllapg2[j] >= 1.11) ou (mllapg12[j] >= 1.11)
então
início
t11[j] = 1.11; //inconsistente
fim

    fim;

//conjugando llnb e llnb1

início
    //normais
se (mllnb2[j] <= 0.6) e (mllnb12[j] <= 0.6) então
início
t12[j] = 0.66; //normal
fim

        //llnb vestibularizado - llnb1 normal
senão se ((llnbp > llnbn) e ((mllnb2[j] > 0.6) e
(mllnb2[j] <= 1.0))) e
(mllnb12[j] <= 0.6) então
início
t12[j] = 0.96; //tende vestibularizado
fim

```

```

//l1nb lingualizado - l1nb1 normal
senão se ((l1nbp < l1nbn) e ((m1l1nb2[j] > 0.6) e
(m1l1nb2[j] <= 1.0))) e (m1l1nb12[j] <= 0.6) então
início
t12[j] = 0.36; //tende lingualizado
fim

//l1nb vestibularizado - l1nb1 vestibularizado
senão se ((l1nbp > l1nbn) e ((m1l1nb2[j] > 0.6) e
(m1l1nb2[j] <= 1.0))) e ((l1nb1p > l1nb1n) e
((m1l1nb12[j] > 0.6) e (m1l1nb12[j] <= 1.0))) então
início
t12[j] = 0.99; // vestibularizado
fim

//l1nb vestibularizado - l1nb1 lingualizado
senão se ((l1nbp > l1nbn) e ((m1l1nb2[j] > 0.6) e
(m1l1nb2[j] <= 1.0))) e ((l1nb1p < l1nb1n) e ((m1l1nb12[j] >
0.6) e (m1l1nb12[j] <= 1.0))) então
início
t12[j] = 1.11; // inconsistente
fim

//l1nb normal - l1nb1 lingualizado
senão se (m1l1nb2[j] <= 0.6) e ((l1nb1p < l1nb1n) e
((m1l1nb12[j] > 0.6) e (m1l1nb12[j] <= 1.0))) então
início
t12[j] = 0.36; // tende lingualizado
fim

//l1nb normal - l1nb1 vestibularizado
senão se (m1l1nb2[j] <= 0.6) e ((l1nb1p > l1nb1n) e
((m1l1nb12[j] > 0.6) e ( m1l1nb12[j] <= 1.0))) então
início
t12[j] = 0.96; // tende vestibularizado
fim

//l1nb lingualizado - l1nb1 lingualizado
senão se ((l1nbp < l1nbn) e ((m1l1nb2[j] > 0.6) e (m1l1nb2[j]
<= 1.0))) e
((l1nb1p < l1nb1n) e ((m1l1nb12[j] > 0.6) e (m1l1nb12[j] <=
1.0))) então
início
t12[j] = 0.33; // lingualizado

```

```

fim

    //l1nb lingualizado - l1nb1 vestibularizado
senão se ((l1nbp < l1nbn) e ((m11nb2[j] > 0.6) e
(m11nb2[j] <= 1.0))) e ((l1nb1p > l1nb1n) e
((m11nb12[j] > 0.6) e (m11nb12[j] <= 1.0))) então
início
t12[j] = 1.11; // inconsistente
fim

senão se (m11nb2[j] >= 1.11) ou (m11nb12[j] >= 1.11) então
início
t12[j] = 1.11; //inconsistente
fim

    fim;

    //conjugando l1gome + apg + nb

início

    //l1gome normal

        // normais
se ((t11[j] >= 0.63) e (t11[j] <= 0.68)) e
((t12[j] >= 0.63) e (t12[j] <= 0.68)) e
(m11gome2[j] <= 0.6 ) então
início
t13[j] = 0.66; //normal
fim

        //apg vestibularizado - nb normal
senão se ((t11[j] >= 0.90) e (t11[j] <=1.0)) e
((t12[j] >= 0.63) e (t12[j] <= 0.68)) e
(m11gome2[j] <= 0.6 ) então
início
t13[j] = 0.92; //tende vestibularizado
fim

```

```

//apg lingualizado - nb normal
senão se (t11[j] <= 0.40) e ((t12[j] >= 0.63) e
(t12[j] <= 0.68)) e (mllgome2[j] <= 0.6) então
início
t13[j] = 0.38; //tende lingualizado
fim

//apg vestibularizado - nb vestibularizado
senão se ((t11[j] >= 0.90) e (t11[j] <= 1.0)) e
((t12[j] >= 0.90) e (t12[j] <= 1.0)) e (mllgome2[j] <= 0.6)
então
início
t13[j] = 0.92; //tende vestibularizado
fim

//apg vestibularizado - nb lingualizado
senão se ((t11[j] >= 0.90) e (t11[j] <= 1.0)) e
(t12[j] <= 0.40) e (mllgome2[j] <= 0.6) então
início
t13[j] = 0.66; // inconsistente considerando llgome
fim

//apg normal - nb lingualizado
senão se ((t11[j] >= 0.63) e ( t11[j] <= 0.68)) e
(t12[j] <= 0.40) e (mllgome2[j] <= 0.6) então
início
t13[j] = 0.66; //normal
fim

//apg normal - nb vestibularizado
senão se ((t11[j] >= 0.63) e (t11[j] <= 0.68)) e
((t12[j] >= 0.90) e (t12[j] <= 1.0)) e (mllgome2[j] <= 0.6)
então
início
t13[j] = 0.66; //normal
fim

//apg lingualizado - nb lingualizado
senão se (t11[j] <= 0.40) e (t12[j] <= 0.40) e
(mllgome2[j] <= 0.6) então
início
t13[j] = 0.38; //tende lingualizado
fim

```

```
//inconsistência
senão se ((t11[j] >= 1.11) ou (t12[j] >= 1.11)) e
(mllgome2[j] <= 0.6) então
início
t13[j] = 0.66; //segue llgome
fim
```

```
//llgome lingualizado
```

```
//normais
senão se ((t11[j] >= 0.63) e (t11[j] <= 0.68)) e
((t12[j] >= 0.63) e (t12[j] <= 0.68)) e
((llgomep < llgomen) e ((mllgome2[j] > 0.6) e
(mllgome2[j] <= 1.0))) então
início
t13[j] = 0.35; //quase seg. lingualizado
fim
```

```
//apg vestibularizado - nb normal
senão se ((t11[j] >= 0.90) e (t11[j] <= 1.0)) e
((t12[j] >= 0.63) e (t12[j] <= 0.68)) e
((llgomep < llgomen) e ((mllgome2[j] > 0.6) e
(mllgome2[j] <= 1.0))) então
início
t13[j] = 0.38; // tende lingualizado
fim
```

```
//apg lingualizado - nb normal
senão se (t11[j] <= 0.40) e ((t12[j] >= 0.63) e
(t12[j] <= 0.68)) e ((llgomep < llgomen) e
((mllgome2[j] > 0.6) e (mllgome2[j] <= 1.0))) então
início
t13[j] = 0.35; //quase seg. lingualizado
fim
```

```
//apg vestibularizado - nb vestibularizado
senão se ((t11[j] >= 0.90) e (t11[j] <= 1.0)) e
((t12[j] >= 0.90) e (t12[j] <= 1.0)) e ((llgomep < llgomen)
e ((mllgome2[j] > 0.6) e (mllgome2[j] <= 1.0))) então
início
t13[j] = 0.38; //inconsistente, prevalece llgome
fim
```

```
    //apg vestibularizado - nb lingualizado
senão se ((t11[j] >= 0.90) e (t11[j] <= 1.0)) e
(t12[j] <= 0.40) e ((llgomep < llgomen) e
(( mllgome2[j] > 0.6 ) e (mllgome2[j] <= 1.0))) então
início
t13[j] = 0.35; //quase seg. lingualizado
fim
```

```
    //apg normal - nb lingualizado
senão se ((t11[j] >= 0.63) e (t11[j] <= 0.68)) e
(t12[j] <= 0.40) e ((llgomep < llgomen) e
((mllgome2[j] > 0.6) e (mllgome2[j] <= 1.0))) então
início
t13[j] = 0.35; // quase seg. lingualizado
fim
```

```
    //apg normal - nb vestibularizado
senão se ((t11[j] >= 0.63) e (t11[j] <= 0.68)) e
((t12[j] >= 0.90) e (t12[j] <= 1.0)) e ((llgomep < llgomen)
e ((mllgome2[j] > 0.6) e (mllgome2[j] <= 1.0))) então
início
t13[j] = 0.38; //inconsistente, prevelece llgome
fim
```

```
    //apg lingualizado - nb lingualizado
senão se (t11[j] <= 0.40) e (t12[j] <= 0.40) e
((llgomep < llgomen) e ((mllgome2[j] > 0.6) e
(mllgome2[j] <= 1.0))) então
início
t13[j] = 0.33; // lingualizado
fim
```

```
senão se ((t11[j] >= 1.11) ou (t12[j] >= 1.11)) e
((llgomep < llgomen) e ((mllgome2[j] > 0.6) e
(mllgome2[j] <= 1.0))) então
início
t13[j] = 0.33; //segue llgome
fim
```



```

//llgome vestibularizado

    //normais
senão se ((t11[j] >= 0.63) e (t11[j] <= 0.68)) e
((t12[j] >= 0.63) e (t12[j] <= 0.68)) e
((llgomep > llgomen) e ((mllgome2[j] > 0.6) e
(mllgome2[j] <= 1.0))) então
início
t13[j] = 0.92; //tende vestibularizado
fim

    //apg vestibularizado - nb normal
senão se ((t11[j] >= 0.90) e (t11[j] <= 1.0)) e
((t12[j] >= 0.63) e (t12[j] <= 0.68)) e
((llgomep > llgomen) e ((mllgome2[j] > 0.6) e
(mllgome2[j] <= 1.0))) então
início
t13[j] = 0.96; //quase seg. vestibularizado
fim

    //apg lingualizado - nb normal
senão se (t11[j] <= 0.40) e ((t12[j] >= 0.63) e
(t12[j] <= 0.68)) e ((llgomep > llgomen) e
((mllgome2[j] > 0.6) e (mllgome2[j] <= 1.0))) então
início
t13[j] = 0.92; // inconsistente, segue llgome
fim

    //apg vestibularizado - nb vestibularizado
senão se ((t11[j] >= 0.90) e (t11[j] <= 1.0)) e
((t12[j] >= 0.90) e (t12[j] <= 1.0)) e ((llgomep > llgomen)
e ((mllgome2[j] > 0.6) e (mllgome2[j] <= 1.0))) então
início
t13[j] = 0.99; //vestibularizado
fim

    //apg vestibularizado - nb lingualizado
senão se ((t11[j] >= 0.90) e (t11[j] <= 1.0)) e
(t12[j] <= 0.40) e ((llgomep > llgomen) e
((mllgome2[j] > 0.6) e (mllgome2[j] <= 1.0))) então
início
t13[j] = 0.92; //tende vestibularizado
fim

```

```

        //apg normal - nb lingualizado
senão se ((t11[j] >= 0.63) e (t11[j] <= 0.68)) e
(t12[j] <= 0.40) e ((llgomep > llgomen) e
((mllgome2[j] > 0.6) e (mllgome2[j] <= 1.0))) então
início
t13[j] = 0.92; // inconsistente, segue llgome
fim

        //apg normal - nb vestibularizado
senão se ((t11[j] >= 0.63) e (t11[j] <= 0.68)) e
((t12[j] >= 0.90) e (t12[j] <= 1.0)) e ((llgomep > llgomen)
e ((mllgome2[j] > 0.6) e (mllgome2[j] <= 1.0))) então
início
t13[j] = 0.96; //quase seg. vestibularizado
fim

senão se ((t11[j] >= 1.11) ou (t12[j] >= 1.11)) e
((llgomep > llgomen) e ((mllgome2[j] > 0.6) e
(mllgome2[j] <= 1.0 ))) então
início
t13[j] = 0.99; //segue llgome
fim

//apg lingualizado - nb lingualizado
senão se (t11[j] <= 0.40) e (t12[j] <= 0.40) e
((llgomep > llgomen) e ((mllgome2[j] > 0.6) e
(mllgome2[j] <= 1.0))) então
início
t13[j] = 0.92; // inconsistente, segue llgome
fim

senão se (t10[j] >= 1.11) e (t11[j] >= 1.11) e
(t12[j] >= 1.11) e (mllgome2[j] >= 1.11) então
início
    t13[j] = 1.11;
fim;

fim;

    fim

```

```

    //considerando só l1gome (snb alto ou baixo)
senão
início

    //lingualizado
se ((l1gomep < l1gomen) e ((m11gome2[j] > 0.6) e
(m11gome2[j] <= 1.0))) então
início
t13[j] = 0.33;
fim

    //vestibularizado
senão se ((l1gomep > l1gomen) e ((m11gome2[j] > 0.6) e
(m11gome2[j] <= 1.0))) então
início
t13[j] = 0.99;
fim

    //normal
senão se (m11gome2[j] <= 0.6) então
início
t13[j] = 0.66;
fim

senão se (t10[j] >= 1.11) e (t11[j] >= 1.11) e
(t12[j] >= 1.11) e (m11gome2[j] >= 1.11) então
início
t13[j] = 1.11; //inconsistente
fim

    senão
início
t13[j] = 1.11; //inconsistente
fim;

    //tratamento das inconsistências de t12 e t11 qdo. snb
//alto ou baixo
início
se (m11apg2[j] >= 1.11) ou (m11apg12[j] >= 1.11) então
início
t11[j] = 1.11;
fim
fim;

```

```
início
se (ml1nb2[j] >= 1.11) ou (ml1nb12[j] >= 1.11) então
  início
  t12[j] = 1.11;
  fim
fim;
```

```
fim; //fim do senão
```

```
fim; //fim da unidade III
```

Apêndice 6

Instruções de uso do programa de análise cefalométrica

Acesso ao programa de análise cefalométrica

Localizar o arquivo executável do programa, no diretório em que estiver arquivado. No exemplo da figura 8.1, o programa está nomeado como “diag3.exe”. Depois de localizá-lo, deve-se “clique” com o mouse duas vezes sobre o nome do arquivo, e na seqüência aparecerá na tela do micro a interface com o usuário do programa.

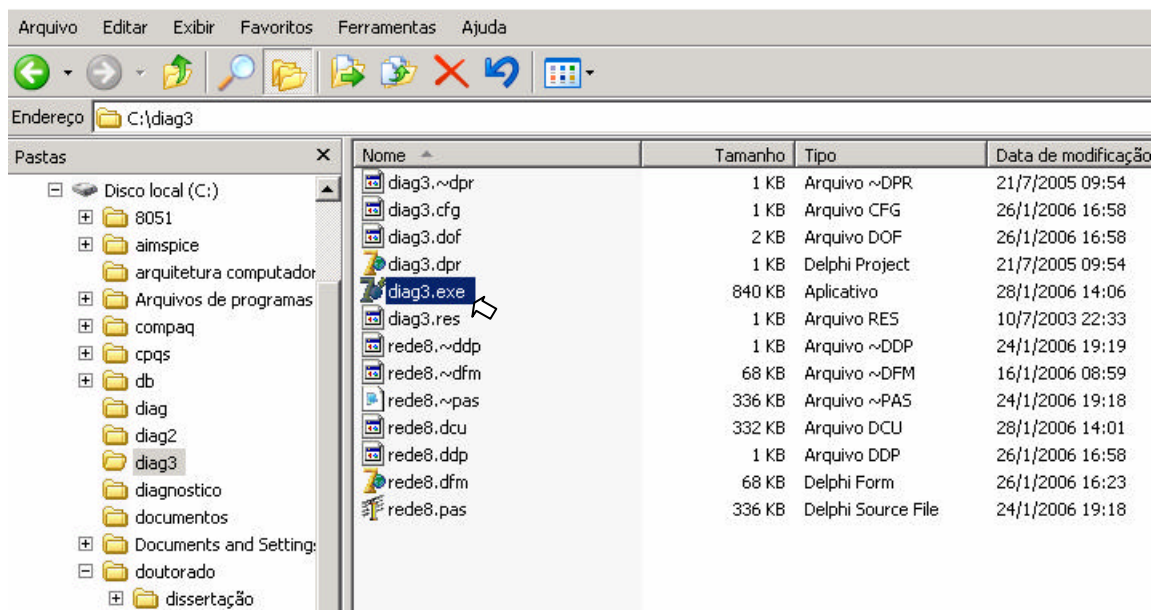


Figura 6.1. Acesso ao programa de análise cefalométrica.

Uso do programa de análise cefalométrica

Na figura 6.2 é mostrada a interface com o usuário do programa de análise cefalométrica.

Inicialmente deve ser identificado o sexo do paciente, clicando com o mouse em “masculino” ou “feminino”.

Na seqüência, no espaço “idade”, deve ser digitada a idade do paciente.

The interface is titled "idade" and includes the following elements:

- Gender Selection:** Radio buttons for "masculino" and "feminino", and a "sistema especialista" button.
- DISCREPÂNCIA ESQUELETAL ANTERO POSTERIOR:** Input fields for SNA, SNB, ANB, and WITS, each with a "grau de evidência" label and two small boxes for input.
- DISCREPÂNCIA ESQUELETAL VERTICAL:** Input fields for Se-Go, Na-Me, Na-ANS, ANSMe, SeNa/PP, SeNa/PD, SeNa/PM, and Eixo Y, each with a "grau de evidência" label and two small boxes. A "Campo II" label is positioned above a larger input field.
- ALTERAÇÕES DENTÁRIAS:** Input fields for U1.SN, U1.PP, U1-NA, L1.GoMe, L1.NB, L1-NB, L1.APg, L1 - APg, and U1.L1, each with a "grau de evidência" label and two small boxes. A "Campo III" label is positioned above a larger input field.
- Treatment Suggestions:** A "Sugestão de Tratamento" label above a large text area, and two smaller "Sugestão de Tratamento" labels above two separate text boxes.
- Diagrams:** Two cephalometric diagrams. The top one shows a lateral view of a head with various landmarks (1-12) and lines. The bottom one shows a similar view with a horizontal line and a vertical dashed line labeled "T".

Figura 6.2. Interface com o usuário do programa de análise cefalométrica.

O próximo passo é digitar as variáveis craniométricas disponíveis do paciente. Os valores destas variáveis deverão ser digitados sempre na primeira coluna, ao lado da identificação de cada variável. Na segunda coluna, será fornecido pelo programa o grau de evidência relacionado a discrepância de cada variável em relação ao seu valor padrão. Não é necessário digitar todas as variáveis para que o programa funcione, porém a resposta do mesmo será mais precisa à medida que o maior número de variáveis seja fornecido.

Quando forem digitadas todas as variáveis disponíveis, deve-se “clique” com o mouse sobre o botão “sistema especialista”. Na sequência, aparecerão os diagnósticos e as sugestões de tratamento, para os campos de discrepância esquelética anteroposterior, vertical, e dentárias.

Para inserir dados de novos pacientes, basta mudar a seleção de sexo, se for necessário, e digitar os novos dados sobre os anteriores.

Quando não se desejar mais utilizar o programa, deve-se clicar no “x” acima, à direita da interface com o usuário.

O trabalho aqui desenvolvido gerou o artigo descrito abaixo e participou do congresso citado:

KES'2005 Conference Melbourne, 14th – 16th September, 2005 - *Paraconsistent Artificial Neural Network: an Application in Cephalometric Analysis.*