

**DETECÇÃO AUTOMÁTICA DE PONTOS CEFALOMÉTRICOS EM
IMAGENS FACIAIS: UMA ABORDAGEM APLICADA NA
ESTIMAÇÃO DE IDADE E SEXO A PARTIR DA NORMA FRONTAL**

LUCAS FARIA PORTO

**TESE DE DOUTORADO EM SISTEMAS MECATRÔNICOS
DEPARTAMENTO DE ENGENHARIA MECÂNICA**

**FACULDADE DE TECNOLOGIA
UNIVERSIDADE DE BRASÍLIA**

**UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA MECÂNICA**

**DETECÇÃO AUTOMÁTICA DE PONTOS CEFALOMÉTRICOS EM
IMAGENS FACIAIS: UMA ABORDAGEM APLICADA NA
ESTIMAÇÃO DE IDADE E SEXO A PARTIR DA NORMA FRONTAL**

LUCAS FARIA PORTO

**TESE DE DOUTORADO ACADÊMICO SUBMETIDA AO DEPARTAMENTO DE
ENGENHARIA MECÂNICA DA FACULDADE DE TECNOLOGIA DA UNIVERSI-
DADE DE BRASÍLIA COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A
OBTENÇÃO DO GRAU DE DOUTOR EM SISTEMAS MECATRÔNICOS.**

APROVADA POR:

**Prof. Dr. Flávio de Barros Vidal, CIC/UnB
(Orientador)**

**Prof. Dr. David Menotti Gomes, INF/UFPR
Membro Externo**

**PCF. Dr. Carlos Eduardo Palhares, INC/DPF
Membro Externo**

**Prof. Dr. Alexandre Romariz, ENE/UnB
Membro Externo**

**Prof. Dr. Díbio Leandro Borges, CIC/UnB
Membro Interno**

BRASÍLIA, 18 DE NOVEMBRO DE 2019.

FICHA CATALOGRÁFICA

LUCAS FARIA PORTO

DETECÇÃO AUTOMÁTICA DE PONTOS CEFALOMÉTRICOS EM IMAGENS FACIAIS: UMA ABORDAGEM APLICADA NA ESTIMAÇÃO DE IDADE E SEXO A PARTIR DA NORMA FRONTAL [Distrito Federal] 2019.

xiv,207p., 210 x 297 mm (ENM/FT/UnB, Doutor, Sistemas Mecatrônicos, 2019).

Tese de Doutorado – Universidade de Brasília, Faculdade de Tecnologia.

Departamento de Engenharia Mecânica

- | | |
|------------------------------|--------------------------|
| 1. Reconhecimento de padrões | 2. Aprendizagem profunda |
| 3. Visão computacional | 4. Pontos cefalométricos |
| 5. Fotoantropometria | 6. Ciência forense |
| I. ENM/FT/UnB | |

REFERÊNCIA BIBLIOGRÁFICA

PORTO, F. L. (2019). DETECÇÃO AUTOMÁTICA DE PONTOS CEFALOMÉTRICOS EM IMAGENS FACIAIS: UMA ABORDAGEM APLICADA NA ESTIMAÇÃO DE IDADE E SEXO A PARTIR DA NORMA FRONTAL, Tese de Doutorado em Sistemas Mecatrônicos, Publicação ENM.TD-XX/2019, Departamento de Engenharia Mecânica, Universidade de Brasília, Brasília, DF, 207p.

CESSÃO DE DIREITOS

AUTOR: Lucas Faria Porto

TÍTULO: DETECÇÃO AUTOMÁTICA DE PONTOS CEFALOMÉTRICOS EM IMAGENS FACIAIS: UMA ABORDAGEM APLICADA NA ESTIMAÇÃO DE IDADE E SEXO A PARTIR DA NORMA FRONTAL.

GRAU: Doutor ANO: 2019

É concedida à Universidade de Brasília permissão para reproduzir cópias desta tese de doutorado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte dessa tese de doutorado pode ser reproduzida sem autorização por escrito do autor.

Lucas Faria Porto

Departamento de Eng. Mecânica (ENM) - FT

Universidade de Brasília (UnB)

Campus Darcy Ribeiro

CEP 70919-970 - Brasília - DF - Brasil

Dedico aos meus pais

AGRADECIMENTOS

Agradeço primeiramente aos meus pais por toda ajuda e por estarem presentes sempre que necessário nesta jornada. Agradeço toda a minha família nesta caminhada em especial as minhas irmãs. Um agradecimento a CAPES, aos professores do departamento de informática da Universidade de Brasília, em especial ao professor Flavio Vidal, este responsável pelo apoio e orientações que resultou nesta tese de doutorado. Um grande obrigado ao grupo Pro-forenses: Laíse, Ademir, Ademar, Marta e principalmente ao Palhares, onde todos não mediram esforços para alcançar os objetivos e fazem parte deste trabalho. Ao pessoal da Espanha, um agradecimento a Universidad de Granada, ao Oscar e principalmente a família que fiz ai: a Gabriella, Luan, Karolina, Carolin, Zé Carlos e ao Juanfran. Não poderia esquecer de agradecer a todos os amigos que fizeram parte desses últimos quatro anos: Bleno, Adam, Faimison, Stefano, Roger, Thais, Joice, Bruna, Elias, Abade, Bicalho, Cobias, Ana Paula, Marcos, Luiz, Vinicius, Lorena, Karlinha, Will, Andrea, Azevedo, Pato, Fabiano e em especial ao grande Igor e seus pais Renata e Márcio.

Muito obrigado a todos!

RESUMO

DETECÇÃO AUTOMÁTICA DE PONTOS CEFALOMÉTRICOS EM IMAGENS FACIAIS: UMA ABORDAGEM APLICADA NA ESTIMAÇÃO DE IDADE E SEXO A PARTIR DA NORMA FRONTAL

Autor: Lucas Faria Porto

Orientador: Prof. Dr. Flávio de Barros Vidal, CIC/UnB

Programa de Pós-graduação em Sistemas Mecatrônicos

Brasília, Novembro de 2019

Métodos forenses para estimação das informações de indivíduos são constantemente utilizados por peritos em cenários reais. O processo forense de estimação de idade e sexo necessita de um profissional capacitado e abordagens que normalmente exigem a presença física do indivíduo para a execução dos procedimentos periciais. A pornografia infantil é uma atividade ilícita que conta com a facilidade da internet para o compartilhamento de imagens e vídeos tornando fácil a disseminação deste tipo de conteúdo e dificultando a identificação e perícia do material. Pesquisas sobre técnicas de reconhecimento de padrões e aprendizado de máquina em visão computacional permitem o desenvolvimento de metodologias baseadas em fotoantropometria para a identificação de informações antropométricas apenas utilizando imagens faciais digitais. Com o avanço da tecnologia e com o aumento do volume de dados, os profissionais necessitam de alternativas para processar as informações antropométricas de indivíduos apenas analisando arquivos digitais. Este trabalho tem como objetivo desenvolvimento de metodologias de identificação automática de pontos cefalométricos em imagens faciais, gerar medidas fotoantropométricas e propor uma solução computacional para auxiliar os profissionais forenses para a estimação da idade e sexo em uma base de dados com 105 mil de imagens faciais. O trabalho proposto para identificação de pontos cefalométricos obteve precisão similar com as marcações realizadas por especialistas com resultado de erro médio da distância (em *pixels*) normalizada de 0.014 contra 0.009 de dispersão média dos testes entre especialistas. Os resultados obtidos demonstram significância no processo de estimação de dados antropométricos, utilizando imagens faciais com redes neurais convolucionais e medidas fotoantropométricas faciais. A proposta desenvolvida obteve resultado de 99,2% de acerto para estimação de sexo. Para estimação de maior/menor de 18 anos o resultado F_1 score foi de 0,926 enquanto para maior/menor de 14 anos foi de 0,957. Por último, estimação de idade, a proposta obteve um resultado MAE de 1,42 utilizando uma amostra de indivíduos com idades entre 2 a 22 anos.

Palavras-Chaves: reconhecimento de padrões, aprendizagem profunda, visão computacional, pontos cefalométricos, fotoantropometria, ciência forense.

ABSTRACT

Author: Lucas Faria Porto

Supervisor: Prof. Dr. Flávio de Barros Vidal, CIC/UnB

Programa de Pós-graduação em Sistemas Mecatrônicos

Forensic methods of estimating information from individuals are constantly used by experts in real scenarios. The forensic process of age and sex estimation requires an expert and approaches that normally need the physical presence of the individual for the execution of the expert procedures. Child pornography is an illicit activity that relies on the ease of the internet to access and disseminate this type of content, making it difficult to identify and exploit the material. Research on pattern recognition techniques and machine learning in computer vision allow the development of methodologies based on photo-anthropometry for identification of anthropometric information using facial images. The advancement of technology and the increasing process of the data volume, the experts need alternatives to be inferring the age and of individuals by analyzing digital files only. This work has the goal to develop methodologies for automatic identification of cephalometric points in facial images, generate photo-anthropometric measurements and propose a computational solution to assist forensic professionals to estimate age and sex in a database with thousands of images. The proposed work to identify cephalometric landmarks obtained similar accuracy with the manual points made by experts with result of normalized average error (in pixels) of 0.014 versus 0.009 of average dispersion by experts. The results present significance in the estimation process of anthropometric data using facial images with convolutional neural networks and facial photo-anthropometric measurements. The developed proposal obtained 99.2% positive results for sex estimation. For the estimation of over 18 years old the result of F_1 was 0.926 while for over 14 years old it was 0.957. Finally, the age estimate, the proposal obtained a MAE result of 1.42 using a sample of individuals over ages from 2 to 22 years old.

Keywords: pattern recognition, deep learning, computer vision, cephalometric landmarks, photo-anthropometry, forensic science.

SUMÁRIO

1	INTRODUÇÃO	1
1.1	MOTIVAÇÃO	3
1.2	OBJETIVOS	4
1.2.1	OBJETIVOS SECUNDÁRIOS	4
1.3	ORGANIZAÇÃO DO MANUSCRITO	5
2	REVISÃO BIBLIOGRÁFICA	6
2.1	PROCEDIMENTOS FORENSES DE ESTIMAÇÃO DE IDADE.....	7
2.2	ESTIMAÇÃO DE DADOS ANTROPOMÉTRICOS POR IMAGENS DIGITAIS.....	8
2.3	FOTOANTROPOMETRIA	11
2.3.1	PONTOS CEFALOMÉTRICOS	12
2.3.2	RAZÕES FOTOANTROPOMÉTRICAS	13
2.4	ESTIMAÇÃO AUTOMÁTICA DE IDADE E SEXO.....	17
3	METODOLOGIA PROPOSTA	24
3.1	BASE DE DADOS DE IMAGENS FACIAIS	24
3.2	IDENTIFICAÇÃO AUTOMÁTICA DOS PONTOS CEFALOMÉTRICOS EM IMAGENS FACIAIS	26
3.2.1	OUTRAS ABORDAGENS DE IDENTIFICAÇÃO AUTOMÁTICA DE PONTOS FACIAIS.....	27
3.2.2	BASE DE DADOS: IMAGENS E PONTOS CEFALOMÉTRICOS.....	28
3.2.3	EXPERIMENTO E MÉTRICAS DE AVALIAÇÃO.....	28
3.3	ESTIMAÇÃO AUTOMÁTICA DE IDADE E SEXO USANDO RAZÕES FOTOANTROPOMÉTRICAS	29
3.3.1	BASE DE DADOS: IMAGENS E PONTOS CEFALOMÉTRICOS.....	30
3.3.2	RAZÕES FOTOANTROPOMÉTRICAS	30
3.3.3	EXPERIMENTOS E MÉTRICAS DE AVALIAÇÃO	31
3.4	ESTIMAÇÃO AUTOMÁTICA DE IDADE E SEXO USANDO IMAGENS FACIAIS E RAZÕES FOTOANTROPOMÉTRICAS	34
3.4.1	BASE DE DADOS: IMAGENS FACIAIS.....	34
3.4.2	EXPERIMENTOS E MÉTRICAS DE AVALIAÇÃO	35
4	RESULTADOS	37
4.1	IDENTIFICAÇÃO AUTOMÁTICA DOS PONTOS CEFALOMÉTRICOS EM IMAGENS FACIAIS	37
4.2	ESTIMAÇÃO AUTOMÁTICA DE IDADE E SEXO USANDO RAZÕES FOTOANTROPOMÉTRICAS	39

4.3 ESTIMAÇÃO AUTOMÁTICA DE IDADE E SEXO USANDO IMAGENS FACIAIS E RAZÕES FOTOANTROPOMÉTRICAS	50
5 DISCUSSÕES	55
5.1 IDENTIFICAÇÃO AUTOMÁTICA DOS PONTOS CEFALOMÉTRICOS	55
5.2 ESTIMAÇÃO AUTOMÁTICA DE IDADE E SEXO	56
6 CONCLUSÕES	60
6.1 TRABALHOS FUTUROS	61
6.2 PUBLICAÇÕES REALIZADAS	62
REFERÊNCIAS BIBLIOGRÁFICAS	64
APÊNDICES	80
A RAZÕES FOTOANTROPOMÉTRICAS	81
B BOXPLOTS RFAS	88

LISTA DE FIGURAS

2.1	SAFF-2D manual de marcação, guia de uso e boas práticas: exemplo de marcação de dois pontos cefalométricos utilizando o <i>software</i> . A esquerda o procedimento de localização do <i>Cheilion</i> , enquanto na direita as instruções para a identificação do ponto <i>Glabella</i>	13
2.2	SAFF-2D: Ferramenta de captura manual dos pontos cefalométricos em imagens faciais bidimensionais; utilizada imagem da face da base de imagens FERET (PHILLIPS <i>et al.</i> , 2000). (a) Modelo para auxiliar o marcador a identificar a região dos pontos cefalométricos. (b) Imagem com linhas auxiliares para auxiliar no processo de marcação.	14
2.3	Representação gráfica da localização na face de todos os 28 pontos cefalométricos adotados neste trabalho: 1. <i>Glabella</i> (g); 2. <i>Nasion</i> (n); 3. <i>Subnasale</i> (sn); 4. <i>Labiale Superius</i> (ls); 5. <i>Stomion</i> (sto); 6. <i>Labiale Inferius</i> (li); 7. <i>Gnathion</i> (gn); 8. <i>Midnasal</i> (m); 9. <i>Endocanthion</i> (en); 10. <i>Exocanthion</i> (ex); 11. <i>Iridion Laterale</i> (il); 12. <i>Iridion Mediale</i> (im); 13. <i>Pupil</i> (pu); 14. <i>Zygion</i> (zy); 15. <i>Alare</i> (al); 16. <i>Gonion</i> (go); 17. <i>Cheilion</i> (ch); 18. <i>Crista Philtri</i> (cph), imagem adaptada de (PHILLIPS <i>et al.</i> , 2000).	16
2.4	Distribuição de idade e sexo das bases de dados de imagens utilizadas em estudos para estimação de idade e sexo por meio de imagens faciais. Imagem adaptada de (XIE; PUN, 2019).	20
2.5	Representação gráfica da distribuição em idades e sexo das imagens da base de dados VisAGe.	21
3.1	Fluxograma da proposta desenvolvida.	25
3.2	Representação gráfica da abordagem automática proposta do algoritmo. Inclui também a abordagem metodológica seguida para treinar o modelo de aprendizagem e validá-lo por meio da validação cruzada em três etapas.	27
3.3	Exemplo da representação gráfica do modelo combinando uma rede neural convolucional com uma rede neural artificial para o treinamento utilizando como entrada da rede imagens faciais e as razões fotoantropométricas.	36
4.1	Diagrama de caixa (<i>Box-plots</i>) para cada ponto cefalométrico medial e por cada abordagem (os três algoritmos automáticos e a dispersão “entre especialistas”).....	40
4.2	Diagrama de caixa (<i>Box-plots</i>) para cada ponto cefalométrico lateral e por cada abordagem (os três algoritmos automáticos e a dispersão “entre especialistas”).....	41

4.3	A distribuição espacial normalizada das marcações realizada pelos vinte especialistas (esquerda) e a abordagem automático proposta (direita).	42
4.4	<i>Boxplots</i> da RFA-10 (asa do nariz - queixo) para cada sexo e faixa etária.....	43
4.5	<i>Boxplots</i> da RFA-160 (lateral da íris - pupila) para cada sexo e faixa etária.	44
4.6	Grupo A: Resultados para estimação de sexo separados por idade, resultado da média das idades e por último, um teste utilizando todas as idades da base de dados.....	44
4.7	Grupo B: Resultado do erro absoluto médio (MAE) para estimação de idade para os quatro cenários teste separados por masculino, feminino e sem o uso da informação de sexo.....	45
4.8	Grupo C: Gráfico com os resultados de F_1 score para estimação de grupos de idade em dois cenários: limiar de 14 e 18 anos de idade. Em ambos cenários são compostos por três etapas: por sexo masculino, feminino e ambos juntos, neste último caso desconsiderando a informação de sexo no classificador.	46
4.9	Matrizes de confusão para estimação de sexo para cada idade (a) até (r), média entre as idades (s) e o teste que engloba todas as idades (t).	47
4.10	Matriz de confusão: estimação de idade com intervalo de 1 em 1 ano.	47
4.11	Matriz de confusão: estimação de idade com intervalo de 1 em 1 ano para sexo feminino.....	48
4.12	Matriz de confusão: estimação de idade com intervalo de 1 em 1 ano para sexo masculino.	48
4.13	Matriz de confusão: estimação de idade com intervalo de 2 em 2 anos.....	48
4.14	Matriz de confusão: estimação de idade com intervalo de 2 anos para sexo feminino.	49
4.15	Matriz de confusão: estimação de idade com intervalo de 2 anos para sexo masculino.	49
4.16	Matriz de confusão: estimação de idade com intervalo de 4 anos.	49
4.17	Matriz de confusão: estimação de idade com intervalo de 5 anos.	50
4.18	Estimação grupo de idade: limiar de 14 anos.....	50
4.19	Estimação grupo de idade: limiar de 18 anos.....	51
4.20	Grupo A: Gráfico dos resultados para estimação de sexo separados por idade e por modelo, sendo eles: utilizando RFAs, utilizando imagens e por último utilizando imagens combinadas com as RFAs.....	52
4.21	Grupo A: Gráfico dos resultados para estimação de sexo geral para cada modelo, sendo eles: utilizando RFAs, utilizando imagens e por último utilizando imagens combinadas com as RFAs.....	52
4.22	Grupo B: Gráfico dos resultados MAE para estimação de sexo separados por idade, resultado da média das idades e por último, um teste utilizando todas as idades da base de dados.	53

4.23 Grupo B: Gráfico dos resultados para estimação de sexo separados por idade, resultado da média das idades e por último, um teste utilizando todas as idades da base de dados.	53
---	----

LISTA DE TABELAS

2.1	Nome e definição dos pontos cefalométricos utilizados para o treinamento do protótipo. Adaptado de (MACHADO, 2015).....	15
2.2	Resultados (MAE) comparativos entre as metodologias existentes no estado da arte para estimação automática de idade. (*) Porcentagem adotada como métrica para avaliar o estudo. (**) Datasets combinados (ANDA <i>et al.</i> , 2018).	22
2.3	Resultados (%) comparativos entre as metodologias existentes no estado da arte para estimação automática de sexo.	23
3.1	A estrutura detalhada da rede neural artificial usada para executar os testes.....	31
3.2	Grupo A: Estrutura dos testes para estimação de sexo.	33
3.3	Grupo B: Estrutura dos testes para estimação de idade.....	33
3.4	Grupo C: Grupo de idade, estrutura dos testes de limiar de idade para 14 e 18 anos.	34
4.1	Erro médio normalizado da distância em <i>pixels</i> por algoritmo.	37
4.2	Distância média do erro em <i>pixels</i> : análise das abordagens automáticas por ponto cefalométrico.	38
4.3	Resultado geral: Especialistas (<i>inter observer</i>) vs abordagens automáticas. Um menor valor representa que os pontos cefalométricos estão concentrados próximos uns dos outros, significando uma melhor acurácia.	39
4.4	Grupo C: Resultados de F_1 score para testes de limiar de idade para menores e maiores de 14 e 18 anos separado por sexo e pelos modelos usando as RFAs, imagens e imagens combinadas com as RFAs.....	52
A.1	Descrição das 208 razões fotoantropométricas (RFAs).....	82

LISTA DE SÍMBOLOS

<i>ageCFBP</i>	Center for Forensics, Biometrics and Privacy age database
<i>AGFAD</i>	Study Group on Forensic Age Diagnostics
<i>ANN</i>	Artificial neural networks
<i>CAPES</i>	Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
<i>API</i>	Application Programming Interface
<i>CNN</i>	Convolutional Neural Networks
<i>CSV</i>	Comma-Separated Values
<i>CPU</i>	Central Processing Unit
<i>GPU</i>	Graphics Processing Unit
<i>HOG</i>	Histogram of Oriented Gradients
<i>ibug</i>	Intelligent Behaviour Understanding Group
<i>IML</i>	Institutos de Medicina Legal
<i>INC</i>	Instituto Nacional de Criminalística
<i>MAE</i>	Mean Absolute Error
<i>PF</i>	Polícia Federal
<i>RFA</i>	Razão Fotoantropométrica
<i>RGB</i>	Red Blue Green
<i>OpenCV</i>	Open Computer Vision Library
<i>SVM</i>	Support Vector Machines

1 INTRODUÇÃO

O conhecimento antropológico pode ser aplicado para apoiar investigações forenses do falecido e do vivo (MARQUEZ-GRANT, 2015). No primeiro, os perfis *post mortem* (PM) das vítimas são reconstruídos para reduzir o número de comparações entre pessoas desaparecidas e corpos desconhecidos, conforme descrito em (SILVA *et al.*, 2013a). O processo de criação de perfil é realizado pela recuperação de informações sobre sexo, idade, estatura e ancestralidade do falecido - especialmente a partir de restos de esqueletos - e comparando-os com dados de *ante mortem* (AM) da suposta vítima (ADSERIAS-GARRIGA *et al.*, 2018). A fim de aumentar a confiabilidade científica, as informações coletadas são combinadas com as evidências de AM e PM obtidas de meios primários de identificação humana, ou seja, as impressões digitais, dentárias e de DNA (INTERPOL, 2018).

Por outro lado, a antropologia forense aplicada ao “indivíduo vivo” geralmente se baseia em informações morfológicas e biométricas de vítimas e suspeitos de crimes registrados em imagens de circuito fechado de televisão e fotografias (CATTANEO *et al.*, 2012; RATNAYAKE *et al.*, 2014). Na última década, os pedidos de exame antropológico dos vivos tornaram-se mais comuns seguindo uma tendência crescente de crimes cibernéticos (CATTANEO *et al.*, 2009). Em caso da identificação de crianças que sofreram exploração sexual, bem como seus autores, figura entre os procedimentos solicitados pela lei na rotina dos institutos médico-legais (BORGES *et al.*, 2018). Esses novos panoramas justificam a necessidade de desenvolver ferramentas avançadas para apoiar o trabalho forense (MACHADO *et al.*, 2017).

A análise forense para identificar pessoas é um processo complexo para o qual podem ser utilizados vários métodos que são executados por agentes especializados, podendo citar como exemplo teste de DNA, papiloscopia, análise dental, entre outros (MACHADO *et al.*, 2017). Entretanto, no que diz respeito à utilização de imagens faciais para os processos forenses de identificação humana, a maioria utiliza abordagens manuais aplicadas por especialistas da área, e para alcançar os resultados esperados é necessário experiência, competência e compromisso do perito durante os testes (DAVIS; VALENTINE; DAVIS, 2010; GIBELLI *et al.*, 2016).

O procedimento fotoantropométrico da face humana surge nesse contexto como uma ferramenta alternativa para busca, coleta e quantificação de características morfológicas e sua aplicação para fins forenses (FLORES *et al.*, 2019). Trabalhando na interface da antropologia forense e da ciência da computação, essa abordagem não invasiva e de baixo custo baseia-se no registro de pontos faciais em imagens e no cálculo de proporções entre distâncias faciais (BORGES *et al.*, 2018; MACHADO *et al.*, 2017; FLORES *et al.*, 2019). A informação morfológica e métrica recuperada da face humana pode ser usada em uma base comparativa, entre indivíduos de referência e alvo, ou numa base reconstrutiva, na qual

o dimorfismo sexual e a estimativa de idade dos vivos são realizados (GONZALES; MACHADO; MICHEL-CROSATO, 2018).

Na utilização de imagens faciais, diversos fatores podem interferir no processo de análise facial e principalmente no resultado. Fatores como a condição da iluminação do ambiente, posicionamento da câmera para a pessoa, posição do rosto e a perda da informação tridimensional ao ser capturado como imagem bidimensional interferem no processo de análise (FLORES, 2014).

Soluções utilizando processamento de imagens e técnicas de visão computacional são uma realidade tendo o foco em melhorar e automatizar o processo forense, permitindo aumentar a precisão do trabalho realizado por um perito (FLORES, 2014). Vários exemplos dessas aplicações podem ser encontradas na literatura, tais como o uso de imagens de raios-X (MONDAL; JAIN; SARDANA, 2011), análises craniofacial usando modelos tridimensionais (XU; XU; MA, 1998; MOSLEH *et al.*, 2008), reconstrução facial (GHAHARI; MOSLEH, 2010), estimação do posicionamento facial (MA *et al.*, 2000), entre outros. Desta maneira, o uso da fotoantropometria pode ser explorado utilizando técnicas automatizadas para a identificação dos pontos cefalométricos em imagens faciais de norma frontal.

Os pontos cefalométricos faciais, tradicionalmente são identificados utilizando imagens capturadas por meio de raio-X (EL-BIALY, 2008), para diversos fins, como exemplo o uso em planejamento ortodôntico (MACHADO, 2015). Geralmente, em análises forenses, o processo de identificação de indivíduos requer que as definições destes pontos sejam obtidos com um elevado grau de precisão na sua localização na região da face. A partir da extração do local correto desses pontos na face é possível identificar o indivíduo, além de extrair informações únicas relevantes, podendo até caracterizar esse indivíduo em um determinado grupo em uma população. O uso de pontos faciais tem sido considerado em diversas áreas forenses, como a identificação de indivíduos vivos (CHEN *et al.*, 2014; LUCAS; KUMARATILAKE; HENNEBERG, 2016), estimação de idade e sexo (MACHADO *et al.*, 2017; BORGES *et al.*, 2018; CATTANEO *et al.*, 2009) ou identificação craniofacial (AULSEBROOK *et al.*, 1995) aplicado em mortos. Todas estas áreas, os pontos faciais são principalmente empregados para medir distâncias, proporções (MARTOS *et al.*, 2018) e para guiar processos de superposição de imagens (CAMPOMANES-ÁLVAREZ *et al.*, 2014). Assim, o desempenho e confiabilidade dessas técnicas são fortemente influenciados pela localização dos pontos e exigem precisão e repetibilidade (FLORES, 2014).

No entanto, na maioria desses cenários, os pontos cefalométricos estão localizados seguindo uma abordagem completamente manual que torna todo o processo subjetivo e fortemente dependente da combinação de três fatores do especialista: habilidade, conhecimento e experiência, como descrito em (BORGES *et al.*, 2018). Além disso as seguintes questões interferem na precisão da localização dos pontos cefalométricos: tipo do ponto, postura facial, resolução da imagem, iluminação da imagem e foco, conforme descrito em (MORETON; MORLEY, 2011). De fato, como descrito em (CAMPOMANES-ÁLVAREZ *et al.*, 2015;

CUMMAUDO *et al.*, 2013), há uma significativa dispersão de localização entre especialistas e também dentro de diferentes processos de localização de um ponto pelo mesmo especialista. Peritos forenses e autoridades policiais usam frequentemente alguma ferramenta forense computacional. Muitos desses *softwares* fornecem recursos que auxiliam (ou orientam) o especialista na identificação da maioria dos pontos cefalométricos. O uso do *software* em conjunto com um guia detalhado demonstrou que é possível reduzir a dispersão de localização, como apresentado em (FLORES; MACHADADO, 2018; FLORES, 2014). Em qualquer caso, a natureza repetitiva do processo, erros relacionados com a fadiga do analista também devem ser considerados. Além disso, até mesmo especialistas treinados precisam de uma quantidade importante de tempo para localizar todos os pontos cefalométricos com precisão.

1.1 MOTIVAÇÃO

Todas as aplicações e problemas descritos justificam a necessidade da automação do processo de localização dos pontos cefalométricos. Pesquisas sobre identificação e análises de características faciais em imagens não são recentes e é possível facilmente encontrar estudos a partir dos anos 80 (SAVAGE; SHOWFETY; YANCEY, 1987; STABRUN; DANIELSEN, 1982; EL-MANGOURY; SHAHEEN; MOSTAFA, 1987). Entretanto, a localização automática de pontos cefalométricos em particular tem atraído cada vez mais o interesse de pesquisadores devido à sua múltipla aplicação em campos como: identificação e reconhecimento facial (WISKOTT *et al.*, 1997; SHI; SAMAL; MARX, 2006; BICALHO *et al.*, 2018), modelagem facial usando imagens 3D (VEZZETTI; MARCOLIN; FRACASTORO, 2014; NUNES; ZAGHETTO; VIDAL, 2018), rastreamento (CECH; FRANC; MATAS, 2014), identificação de pontos cefalométricos (LE-TIEN; PHAM-CHI, 2014), estimação de sexo e idade (DIBEKLIOGLU *et al.*, 2015; PATIL; MODY, 2005) e assim por diante. Diversos estudos têm sido propostos para identificação automática de pontos faciais (HUBER *et al.*, 2015; XIONG; TORRE, 2013; KING, 2009). Entre as várias técnicas de imagem, o reconhecimento de padrões em visão computacional é a mais popular (BURGOS-ARTIZZU; PERONA; DOLLÁR, 2013). No entanto, estas abordagens existentes para identificação automática dos pontos faciais apresentam uma limitação para o campo forense, o conjunto de pontos faciais reconhecidos por esses algoritmos não são os cefalométricos (PORTO *et al.*, 2019).

A globalização da informação permitiu a quebra de fronteiras e novas possibilidades de interação entre os povos no mundo, disponibilizando uma democratização da comunicação, facilitando o uso pessoal e até abrindo novos horizontes no mercado econômico (CASTELLS, 2003). Essa mesma facilidade gerada pelo avanço tecnológico permitiu o surgimento de novos meios para atuações ilegais, os quais neste caso, são utilizados para crimes cibernéticos como roubos, extorsões, difamações, entre outros (NETO; GUIMARÃES,

2003). Nos diversos crimes praticados na rede mundial de computadores, em que há a troca de imagens pornográficas de crianças e adolescentes, é uma luta diária identificar os criminosos, seja este crime fisicamente tirando as fotos, seja contra aqueles que disponibilizam compartilhando esse tipo de conteúdo na rede (MACHADO, 2015).

Com a grande quantidade de material pornográfico digital existente, possibilitar a separação do conteúdo de pedofilia de outro, atualmente, é uma tarefa árdua e complexa (CATTANEO *et al.*, 2009). Mesmo peritos treinados necessitam fazer uma análise minuciosa no material apreendido, a fim de obter provas contra os criminosos (BORGES *et al.*, 2018). Neste processo de análise, é necessária a averiguação de todos os arquivos digitais (imagens e vídeos), exigindo muito tempo e recursos para tal tarefa. Por se tratar de um processo repetitivo, o fator humano pode falhar resultante da exaustão mental (MACHADO, 2015).

A computação forense, como descrito anteriormente, já é utilizada como opção para automatizar algumas tarefas realizadas por peritos e especialistas forenses. Empregar *softwares* para a identificação de conteúdo de pornografia infantil é uma área de interesse de pesquisas (RATNAYAKE *et al.*, 2014). Estudos estão sendo realizadas para permitir a estimação da idade de um indivíduo utilizando a análise do conteúdo digital de imagens e vídeos (HAYASHI *et al.*, 2002; RONDEAU; ALVAREZ, 2018; ANDA *et al.*, 2019). Em (RATNAYAKE *et al.*, 2014) descreve-se um estudo desenvolvido para identificar casos de pedofilia (RATNAYAKE *et al.*, 2014) usando imagens faciais. Entretanto, a falta de padronização nas base de dados e amostras de imagens faciais dificulta os resultados de representarem uma amostra em âmbito populacional como apresentado em (RICANEK; TESAFAYE, 2006; MOSCHOGLU *et al.*, 2017; FU *et al.*, 2014).

1.2 OBJETIVOS

O objetivo principal deste trabalho é desenvolver técnicas computacionais que implementem uma solução automática para o processo de estimação de idade e sexo utilizando imagens faciais e métricas baseadas nos pontos cefalométricos faciais de norma frontal.

1.2.1 Objetivos secundários

Para alcançar este objetivo, o presente trabalho é dividido em três partes, sendo estes objetivos secundários, a saber: extração automática dos pontos cefalométricos, análises das razões fotoantropométricas baseadas nos pontos cefalométricos para estimação de idade e sexo e, por fim, o uso de técnicas de aprendizagem profunda combinada com as razões fotoantropométricas.

Para a identificação automática dos pontos cefalométricos, este trabalho pretende preencher a lacuna sobre a localização automática dos pontos por meio de uma nova adaptação

das abordagens existentes (HUBER *et al.*, 2015; XIONG; TORRE, 2013; KING, 2009) ao problema em particular da detecção automática de pontos cefalométricos em imagens de face frontal. Este objetivo específico foi abordado nestas três tarefas seguintes: i) Análise dos algoritmos automáticos disponíveis para a localização de pontos faciais; ii) Propor uma nova metodologia especialmente desenhada para identificação de pontos cefalométricos; iii) Estudo de desempenho das abordagens existentes adaptado seguindo a metodologia proposta e comparação entre eles e a dispersão de especialistas humanos.

Na segunda parte, análises das razões fotoantropométricas, este estudo foi delineado com quatro objetivos para o uso de dados antropométricos da face humana: i) Propor uma solução automática baseada em Rede Neural Artificial para estimar informações antropológicas utilizando as razões fotoantropométricas; ii) Testar a acurácia diagnóstica da solução com pontos de corte limite entre indivíduos do sexo masculino e feminino de limiar para as idades de 14 e 18; iii) Analisar a correlação entre sexo e idade utilizando as razões fotoantropométricas da face humana.

A terceira parte tem como objetivo analisar técnicas existentes de Redes Neurais profundas e combiná-las com a abordagem anterior (razões fotoantropométricas) para solucionar os mesmos problemas apresentados anteriormente alcançando melhora na acurácia. Esta última parte do estudo dispõe de 3 três objetivos: i) Avaliar o desempenho de uma rede neural profunda utilizando apenas imagens como entrada; ii) Propor um novo modelo que combine uma rede neural profunda (imagens) com uma rede neural artificial (razões fotoantropométricas) em canais de entrada separados; iii) Testar acurácia deste novo modelo e atestar se as razões fotoantropométricas contribuem na acurácia do processo automático de estimação de idade e sexo.

1.3 ORGANIZAÇÃO DO MANUSCRITO

A presente tese está dividida e organizada em capítulos, como descrito a seguir: O Capítulo 2 aborda os conceitos históricos e características importantes da área de antropologia e de tecnologia no processo de estimação de idade e sexo em indivíduos. No Capítulo 3, é apresentada a metodologia proposta no desenvolvimento das técnicas elaboradas neste trabalho, apresentando detalhes e abordagens relevantes para se alcançarem os objetivos propostos. São apresentados os resultados das metodologias desenvolvidas no Capítulo 4, sendo discutidas questões como os resultados obtidos, acurácia e comparativos com outras abordagens existentes na literatura. No Capítulo 5 é contemplada uma discussão dos resultados do tema em questão. Por fim, no Capítulo 6, são descritas as principais conclusões do presente estudo e trabalhos futuros.

2 REVISÃO BIBLIOGRÁFICA

Neste capítulo é apresentada a revisão bibliográfica do tema proposto em que são discutidos os trabalhos das áreas correlatas. Dentre essas áreas, abordam-se conceitos das áreas da medicina legal, ciência forense e computação. Os trabalhos aqui mencionados demonstram a relevância de pesquisas no tema e suas principais características e desafios.

O processo de extração de informações utilizando análises faciais para diversas finalidades, nas quais podemos citar: identificação de expressões faciais (SAMAL; IYENGAR, 1992), análise de emoções (MAYER; GEHER, 1996), estudos antropométricos da face (FARKAS; KATIC; FORREST, 2005), análises de modelos tridimensionais crânio-faciais (XU; XU; MA, 1998; MOSLEH *et al.*, 2008), estimação facial a partir do perfil (MA *et al.*, 2000), aplicações de inteligência artificial para fins biométricos (JAIN *et al.*, 1999), entre outros.

O autor em (LANITIS, 2002) relata que maioria das pesquisas que utilizam técnicas de análises faciais estão relacionados a identificar padrões em cores e formas geométricas. De acordo com o autor em (DEMAYO *et al.*, 2010) estas abordagens permitem o estudo e a identificação dos padrões de características para inferir determinadas informações por meio de associações, variações ou heranças em uma determinada amostra. Como exemplo têm-se os estudos de biometria facial, em que as técnicas utilizam os padrões faciais para a identificação de um indivíduo em aplicações de segurança (BICALHO *et al.*, 2018; ZHAO *et al.*, 2003), classificação de gênero para estimação do sexo (MAKINEN; RAISAMO, 2008; JAIN; HUANG, 2004) e ancestralidade (KLIMENTIDIS; SHRIVER, 2009).

Em um contexto prático, os profissionais dos Institutos Médico-Legais (IMLs) utilizam vários procedimentos de identificação humana para exames de estimativa de idade (FRANCISCO *et al.*, 2011; IDADE, 2006). Estes profissionais, normalmente, são das áreas de Antropologia Forense, Odontologia e Medicina, utilizam os métodos de estimação da idade em processos legais e criminais como base científica em investigações de delitos, acidentes em larga escala e crimes de várias proporções (SCHMELING *et al.*, 2007).

O autor em (MACHADO, 2015) descreve que o processo de identificação de indivíduos para fins forenses é uma tarefa recorrente e demanda um conjunto de análises a serem realizadas pelo especialista. Dentre as principais técnicas utilizadas atualmente (Biometria, análise dentária, exame de DNA, etc.), a grande maioria delas faz uso de abordagens manuais em sua realização, em que o sucesso do resultado esperado depende da experiência, expertise e empenho do perito durante o procedimento. Diversos fatores, além da qualidade do material a ser periciado, influenciam nessa análise, principalmente o desgaste físico do perito, causado pelos diversos procedimentos levando-o à exaustão, que tende a comprometer a qualidade das análises realizadas.

Um ponto importante nesse processo de análise citado anteriormente é a necessidade da

presença física do indivíduo, que pode estar vivo ou morto, uma vez que a análise também pode ser executada em um corpo ou restos mortais (HENNESSY; STRINGER, 2002). O autor em (MACHADO, 2015) descreve que a necessidade da análise presencial pode se tornar um problema quando exigir o transporte da pessoa a ser analisada até o perito ou o deslocamento do perito até o local no qual será executado o processo pericial, novamente atrapalhando e/ou influenciando nos resultados das análises.

2.1 PROCEDIMENTOS FORENSES DE ESTIMAÇÃO DE IDADE

O perito pode utilizar diversas técnicas para estimar a idade em um cadáver e em restos mortais. Esses métodos podem ser classificados como uma abordagem invasiva e não invasiva. Entretanto, ao executar tais procedimentos em pessoas vivas, o perito deve optar, quando possível, técnicas que não afetem a integridade física e psicológica do periciado (MACHADO, 2015). De acordo com (SCHMELING *et al.*, 2007) recomendações definidas pelo Grupo de Estudos em Diagnóstico Forense de Idade (AGFAD), um processo de estimativa de idade em procedimentos criminais deve obedecer à execução de três abordagens combinadas, sendo elas:

1. Identificação por maturação sexual: Exame físico que determina a identificação de características corporais recorrentes ao desenvolvimento corporal;
2. Radiografia carpal: Análise visual do punho utilizando imagens geradas por raio-X;
3. Exame odontológico: Análise visual em imagens geradas em radiografias da estrutura dentária do indivíduo;

Um procedimento de estimativa de idade é a análise dos parâmetros propostos por Tanner (MARSHALL; TANNER, 1969), em que se utiliza um exame visual do resultado do desenvolvimento corporal durante a puberdade. Nesse processo é possível notar nas mulheres o aparecimento de pelos pubianos e o desenvolvimento das glândulas mamárias, enquanto nos homens nota-se o crescimento dos pelos pubianos, testículos e pênis.

O outro processo de estimativa da idade citado anteriormente é a análise de imagens do punho capturadas com raio-X. Neste procedimento é possível visualizar o estágio do desenvolvimento ósseo em seis momentos da vida de um indivíduo. Entretanto, esse procedimento só é possível de ser utilizado no processo de estimativa de idade em pessoas jovens pois durante o procedimento da radiografia carpal, é analisado o desenvolvimento dos ossos longos e seus núcleos epifisários. Caso contrário, é necessário outro procedimento, uma radiografia da epífise medial da clavícula, para inferir se o indivíduo possui idade superior a 21 anos, pois desenvolvimento nos ossos do punho se encontra inerte (SCHMELING *et al.*, 2007; FRANÇA, 2001).

O último procedimento recomendado pelo Grupo de Estudos em Diagnóstico Forense de Idade é o processo de estimacão de idade utilizando exames odontológicos não invasivos. Estes devem ser realizados por profissionais da área utilizando radiografia panorâmica da arcada dentária, a qual permite identificar sinais de envelhecimento do indivíduo.

Em todos os três casos citados anteriormente, existem pontos negativos no procedimento de estimacão de idade. No primeiro, referente à maturacão sexual, é necessária a análise visual do indivíduo, sendo complexo inferir com exatidão a informacão da idade que pode causar equívocos neste processo. A segunda abordagem de estimacão de idade proposta por Tanner, o indivíduo é exposto a radiação durante o exame de raios-X, isso também ocorre no terceiro método. Outro ponto importante nos três casos, é a necessidade da presença física do indivíduo a ser periciado, mas dependendo do contexto, pode não ser possível contar com a presença física.

2.2 ESTIMACÃO DE DADOS ANTROPOMÉTRICOS POR IMAGENS DIGITAIS

Conforme apresentado anteriormente, a face humana permite a extração de várias informacões do indivíduo. Entretanto, os efeitos da idade apresentam 3 características únicas, como descrito em (GENG; ZHOU; SMITH-MILES, 2007), sendo:

1. Não é possível controlar o processo de envelhecimento. Este processo ocorre lentamente e sem reversão;
2. Não é possível definir um padrão no processo de envelhecimento. O processo varia para cada indivíduo, em razão de informacões genéticas e também dos fatores externos, como alimentacão, estilo de vida, clima, etc.
3. Envelhecimento está ligado diretamente com a informacão cronológica, sendo que o processo de envelhecer obedece à ordem temporal. A aparência física de um rosto em uma determinada idade avançada contém características que afetam outras pessoas na mesma situacão, sendo assim estas não ocorrem em rostos jovens.

De acordo com Geng, Zhou e Smith-Miles (2007), essas características citadas anteriormente, que interferem no processo de estimacão automática da idade, e não se ter o controle do processo de envelhecimento individual são alguns dos grandes desafios nesta área de pesquisa. Outra dificuldade apresentada por Geng, Zhou e Smith-Miles (2007) é a falta de base de dados com variações de idade, sexo e raça suficientes para se representar uma amostra real da populacão, que permitisse efetuar treinamentos dos sistemas automatizados e também os testes dos protótipos. Neste contexto, existem bases de dados de imagens faciais públicas para pesquisas (JAIN; LEARNED-MILLER, 2010; VALSTAR *et al.*, 2011; PHILLIPS *et*

al., 2000; GALLAGHER; CHEN, 2009). Entretanto estas não contêm informações de idade necessárias para pesquisas sobre o envelhecimento.

Existem bases de dados públicas com imagens faciais que abordam o envelhecimento, como apresentado em (RICANEK; TESAFAYE, 2006), que infelizmente ainda possuem problemas significativos, como, por exemplo, falta de indivíduos com idade abaixo dos 16 anos de idade. Já a base de dados ageCFBP (*Center for Forensics, Biometrics and Privacy age database*) (GRD; BAČA, 2016) contém 242 imagens de 82 indivíduos não contemplando todas as faixas etárias. Este assunto é apresentado com mais detalhes a seguir na Seção 2.4.

O autor em (WANG; TAO; YANG, 2016) descreve que nos estudos de estimação de idade utilizando procedimentos computacionais automatizados são encontradas dificuldades para se alcançar o objetivo desejado. Wang, Tao e Yang (2016) reforçaram que além do processo de envelhecimento ter grande variabilidade entre pessoas, esse processo, em pouco tempo, pode variar drasticamente no mesmo indivíduo analisado, sendo assim o mesmo pode ter sua aparência apresentando diferenças, podendo ser classificado como mais velho ou mais novo no mesmo ano. Toda essa variação pode ocorrer dependendo do uso de produtos de estética/maquiagens, variação de humor e a alterações em sua condição de saúde.

De acordo com Wang, Tao e Yang (2016), já existem intensos esforços nas pesquisas nesta área nos últimos anos. Em geral, normalmente, estas podem ser classificadas em três subgrupos na abordagem para a identificação de idade em imagens faciais, sendo elas: regressão, classificação de multiclases e classificação baseada em ranqueamento. As pesquisas mais recentes, como a apresentada em (BEKHOUCHE *et al.*, 2016), utilizam técnicas combinadas para auxiliar o processo ao inferir uma determinada idade. Nelas podem ser combinados treinamentos de classificação com características faciais, e até mesmo processamentos de imagens como rotações a fim de definir a face em uma posição que ajude o algoritmo na identificação. Em sua pesquisa, Wang, Tao e Yang (2016) utilizou as características faciais para o treinamento de um classificador baseado em máquina de vetores de suporte (do inglês *Support Vector Machine* - SVM), foram definidos como atributos do treinamento as seguintes informações: a suavidade da pele, formato do rosto (arredondamento), tamanho rosto, rugas, olheiras, acne, maquiagem, brilho facial, elasticidade da pele e bigode.

Com o avanço da tecnologia e da ciência, é inevitável o surgimento de novos estudos e técnicas nas diversas áreas do conhecimento, e na computação não é diferente. O uso das redes neurais convolucionais (do inglês *Convolutional Neural Networks* - CNN), apresentaram avanços de classificação usando imagens (SZEGEDY *et al.*, 2017; STADELMANN *et al.*, 2019). Esta abordagem demonstrou avanços significativos como solução no processo de identificação e reconhecimento de objetos utilizando imagens (KRIZHEVSKY; SUTSKEVER; HINTON, 2012). Com estes avanços surgiram pesquisas usando imagens faciais aplicadas em redes neurais convolucionais, onde podemos citar reconhecimento facial (DENG *et al.*, 2019), reconhecimento de emoções em faces (HOSSAIN; MUHAMMAD, 2019), reconhecimento de sorrisos em vídeos (NGUYEN *et al.*, 2019), estimação da pose facial (XU;

CHEN; GAN, 2019), estimação de idade (RONDEAU; ALVAREZ, 2018) e de sexo (HAN *et al.*, 2017). Novas abordagens e melhorias nas CNN estão sendo propostas pela comunidade científica (CIREGAN; MEIER; SCHMIDHUBER, 2012), alternativa como um classificador CNN em cascata (CHEN *et al.*, 2016) e até mesmo combinando esta com outras metodologias, tal como SVM para melhorar o processo de classificação (RAZAVIAN *et al.*, 2014).

Entretanto, os autores supracitados evidenciam as dificuldades de se trabalhar com as CNN's que são elas: i) Alto custo computacional; ii) O processo de treinamento é lento iii) Necessita de uma base de dados com tamanho considerável de amostras. O autor em (TAN; LE, 2019) descreveu uma abordagem para CNN para manter a mesma eficiência em redes neurais convolucionais fazendo um equilíbrio da profundidade da rede e seus recursos. Atualmente, as *frameworks* como Caffe (JIA *et al.*, 2014), Tensorflow (ABADI *et al.*, 2015), Theano (Theano Development Team, 2016) e PyTorch (PASZKE *et al.*, 2017) vêm ganhando grande destaque na comunidade científica, por consequência da facilidade para gerar e modificar classificadores complexos utilizados redes neurais convolucionais. Entretanto, as redes neurais convolucionais ainda sofrem com os problemas citados anteriormente: a vasta quantidade de imagens necessárias no processo de generalização do classificador. Por exemplo, a base VGGFace2 (CAO *et al.*, 2018) utilizada para reconhecimento facial dispõe mais de 3 milhões de imagens. Essa quantidade de imagens necessita de um grande poder de processamento para alcançar os resultados desejados, proveniente de uma arquitetura computacional não trivial que permita explorar um alto poder de processamento por meio de computação paralela usando placas de vídeo resultando em um processo complexo, caro e lento.

Os trabalhos apresentados em (LEVI; HASSNER, 2015; ROTHE; TIMOFTE; GOOL, 2015; LIU *et al.*, 2015a; HAN *et al.*, 2017) já demonstraram o interesse do uso das CNN como proposta para solucionar os desafios da estimação da idade utilizando imagens faciais. O autor em (ESCALERA *et al.*, 2015) descreve que essas pesquisas usando imagens faciais são apresentadas como soluções promissoras em desafios científicos as quais são comparados para testar a precisão das abordagens implementadas no processo de estimação de idade. Mesmo que a abordagem utilizando redes neurais convolucionais seja promissora, o autor em (ROTHE; TIMOFTE; GOOL, 2015) reforça a importância da combinação desta com a técnica detecção dos pontos faciais para melhorar a acurácia dos resultados. Combinar abordagens distintas para o processo de estimação de idade não é recente. No trabalho apresentado em (KWON; LOBO, 1994), os autores já abordavam esse princípio, eles utilizavam outras informações combinadas com os pontos faciais para auxiliar o processo de estimação, sendo elas: a formação de rugosidades na pele, a informação de tamanho e formato do rosto, distâncias entre regiões da face, todas estas com o propósito de permitir distinguir recém nascidos de adultos.

O autor em (LEE; RO, 2014) descreveu que, de maneira semelhante ao processo de estimação de idade usando imagens, a aplicabilidade das características antropométricas

oriundas de imagens faciais estão sendo estudadas por pesquisadores. Como descrito anteriormente pesquisas usando imagens faciais em redes neurais convolucionais estão sendo realizadas. No trabalho apresentado em (NARANG; BOURLAI, 2016) demonstra a utilização de imagens faciais para estimação de sexo enquanto autor em (ČECHOVÁ *et al.*, 2019) utilizou imagens da parte frontal do crânio para o mesmo fim. Diferente da CNN, o autor em (NGUYEN; HUONG, 2016) extraiu características faciais aplicadas em treinamento com SVM para gerar um classificador para estimação de sexo. Enquanto o autor em (KLIMENTIDIS; SHRIVER, 2009) descreveu uma pesquisa sobre ancestralidade utilizando as características faciais usando imagens digitais. Com o foco principal na coloração da pele facial, os pesquisadores conseguiram efetuar uma correlação da tonalidade com a informação genética relacionada com ancestralidade de grupos classificados em asiáticos, africanos, americanos, caucasianos e hispânicos.

2.3 FOTOANTROPOMETRIA

O autor em (KLEINBERG; VANEZIS; BURTON, 2007) define a antropometria como o estudo de medidas do corpo humano para realizar classificações e comparações antropológicas. De acordo com o trabalho proposto em (FLORES, 2014) pesquisas antropométricas da população, os padrões faciais permitem estudos com aplicações em diversas áreas, tais como: avaliação facial do crânio utilizado em estudos da indústria, evolução populacional, ancestralidade, anomalias, planejamento em processos cirúrgicos, processos estéticos, entre outros. Enquanto isso o autor em (MACHADO, 2015) descreve que nas pesquisas antropológicas, odontológicas e da medicina legal, os estudos da análise populacional utilizando faces normalmente utiliza a identificação de padrões nas marcações craniofaciais. Estes padrões permitem a identificação do processo de envelhecimento e identificação de características, como exemplo o sexo.

A fotoantropometria facial permite a análise das características em imagens de faces humanas por meio de métodos antropométricos (MACHADO, 2015; MACHADO *et al.*, 2019). A autora em (FLORES, 2014) descreve a fotoantropometria aplicada em imagens faciais como procedimentos que permitem comparar faces utilizando análises métricas, sendo elas as medidas e ângulos usando os pontos cefalométricos. Utilizando a fotoantropometria, como apresentado em (FLORES, 2014), a autora apresentou uma metodologia qualitativa do procedimento de coleta manual dos pontos cefalométricos em imagens faciais da norma frontal. Em seu trabalho, Flores (2014) definiu as variabilidades e métricas no processo de aferição dos pontos cefalométricos aplicada em fotoantropometria, e também como contribuição, a definição em sua metodologia, uma análise para cada ponto.

O autor em (MACHADO, 2015) propôs um estudo detalhado sobre a fotoantropometria facial em norma frontal. Machado (2015) efetuou análises de correlação das medidas da face

usando os pontos cefalométricos faciais com os dados antropométricos. Neste contexto, foi definida uma metodologia de coleta manual baseada dos pontos cefalométricos e a análise dos mesmos (FLORES, 2014). Essa métrica tem como objetivo apresentar uma nova abordagem para testes periciais sendo uma alternativa às outras apresentadas na Seção 2.1, pois minimiza a quantidade de deslocamentos do indivíduo para um laboratório/consultório para os exames clínicos, e principalmente, não necessita da presença física do corpo para a execução de um determinado procedimento. Este último se faz possível, pois a metodologia desenvolvida pelo autor foi baseada na identificação dos pontos utilizando imagens faciais e as informações pessoais (antropológicas) dos mesmos. Esta abordagem é detalhada a seguir na Subseção 2.3.2.

2.3.1 Pontos cefalométricos

O processo de identificação e extração de características faciais não é uma área recente nos estudos científicos, de acordo com o apresentado em (EL-MANGOURY; SHAHEEN; MOSTAFA, 1987). Entre os estudos utilizando os pontos faciais (do inglês *facial landmarks*) podemos citar: identificação e reconhecimento facial (WISKOTT *et al.*, 1997; SHI; SAMAL; MARX, 2006), aplicações e reconstrução facial utilizando três dimensões (VEZZETTI; MARCOLIN; FRACASTORO, 2014), rastreamento em imagem (CECH; FRANC; MATAS, 2014), detecção de pontos cefalométricos (LE-TIEN; PHAM-CHI, 2014), estimação da idade (DIBEKLIOGLU *et al.*, 2015), entre outros.

Em (MACHADO, 2015) foram mapeados manualmente 28 pontos cefalométricos em cada imagem facial do total de 1.000 indivíduos utilizando o *software* SAFF-2D (FLORES; MACHADADO, 2018). Este é o mesmo *software* utilizado pelos peritos forenses e pesquisadores. Essa ferramenta auxilia o perito na análise da imagem facial e no processo de marcação, uma vez que permite a inserção de linhas auxiliares, círculos e outras formas geométricas, ajudando-o a localizar determinados pontos na face (FLORES, 2014). Na Figura 2.2 é possível visualizar um exemplo para a utilização da ferramenta manual de coleta dos pontos cefalométricos em imagens faciais de norma frontal. No trabalho apresentado em (FLORES *et al.*, 2019) descreve que juntamente com o *software* especializado para marcação manual, foi desenvolvido um guia de melhores práticas para o processo de coleta manual dos pontos, com o foco de padronizar a localização das marcações com o objetivo de reduzir a dispersão dos pontos entre os especialistas (Figura 2.1 apresenta a descrição detalhada da localização correta de dois pontos cefalométricos).

Conforme apresentado em (MACHADO *et al.*, 2017) e (BORGES *et al.*, 2018), um especialista identificou manualmente 28 pontos cefalométricos em todas as 1.000 imagens seguindo as etapas de instruções descritas em (FLORES; MACHADADO, 2018). A lista completa dos pontos cefalométricos selecionados, de acordo com a nomenclatura padrão de Caple e Stephan (2016), é a seguinte: *Endocanthion* (en), *Exocanthion* (ex), *Iridion late-*

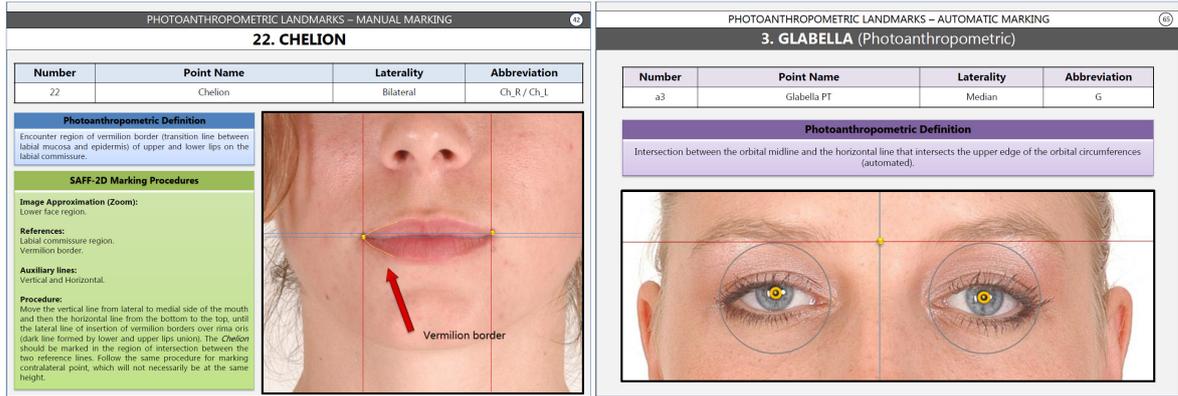


Figura 2.1: SAFF-2D manual de marcação, guia de uso e boas práticas: exemplo de marcação de dois pontos cefalométricos utilizando o *software*. A esquerda o procedimento de localização do *Cheilion*, enquanto na direita as instruções para a identificação do ponto *Glabella*.

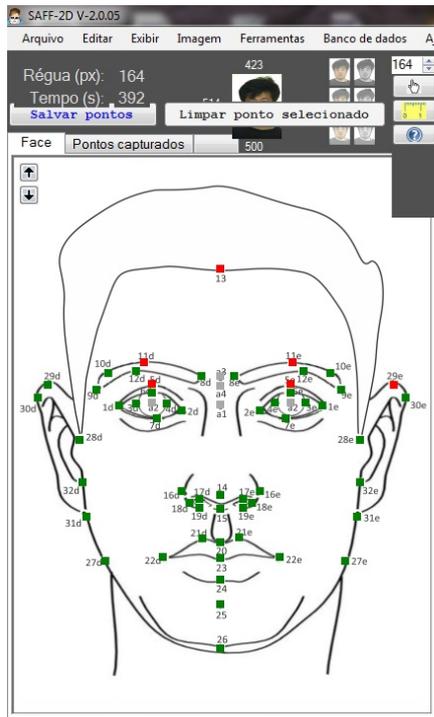
rale (il), *Iridion mediale* (im), *Pupil* (pu), *Zygion* (zy), *Alare* (al), *Gonion* (go) and *Cheilion* (ch), *Crista philtri* (cph) para os pontos bilaterais. O restante pode ser encontrado na linha média do rosto como: *Glabella* (g), *Nasion* (n), *Subnasale* (sn), *Labiale superius* (ls), *Stomion* (sto), *Labiale inferius* (li), *Gnathion* (gn), *Midnasal* (m) (BROWN *et al.*, 2004). Na Tabela 2.1 são descritos detalhadamente todos os cefalométricos, reiterando que esses pontos faciais foram coletados usando imagens faciais de norma frontal resultando em diferentes localizações *in vivo*, enquanto na Figura 2.3 apresenta todos os estes devidamente localizados na face.

2.3.2 Razões Fotoantropométricas

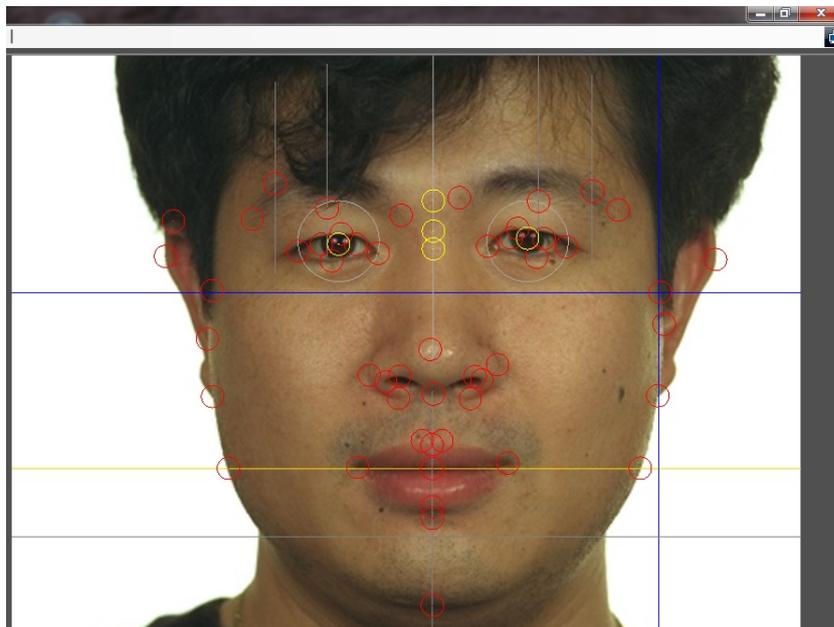
A dispersão dos pontos cefalométricos, ao longo da face humana, varia conforme o sexo, idade e raça, como apresentado em (PRENDERGAST, 2012; FU; GUO; HUANG, 2010; CUMMAUDO *et al.*, 2014). O diferencial apresentado na metodologia proposta por (MACHADO, 2015), que é a base do estudo utilizada neste trabalho, foi a adoção da projeção da distância iridiana como parâmetro para calcular as razões fotoantropométricas, diferentemente das abordagens propostas em (CATTANEO *et al.*, 2012; CUMMAUDO *et al.*, 2014). A Equação 2.1 apresenta a definição matemática para o cálculo da projeção da distância iridiana (P_{iris}), a qual é composta pela média das somas das diferenças utilizando os pontos *iridion mediale* esquerdo (im_e), *iridion mediale* direito (im_d), *iridion laterale* esquerdo (il_e) e *iridion laterale* direito (il_d).

$$P_{iris} = \frac{(|im_e - il_e|) + (|im_d - il_d|)}{2}. \quad (2.1)$$

Com a informação iridiana em (MACHADO, 2015) foi definida as quinze razões fotoantropométricas de sua pesquisa, analisando a correlação dos pontos com o fator da íris. Com



(a)



(b)

Figura 2.2: SAFF-2D: Ferramenta de captura manual dos pontos cefalométricos em imagens faciais bidimensionais; utilizada imagem da face da base de imagens FERET (PHILLIPS *et al.*, 2000). (a) Modelo para auxiliar o marcador a identificar a região dos pontos cefalométricos. (b) Imagem com linhas auxiliares para auxiliar no processo de marcação.

Tabela 2.1: Nome e definição dos pontos cefalométricos utilizados para o treinamento do protótipo. Adaptado de (MACHADO, 2015)

Ponto Cefalométrico	Descrição
1. <i>Glabella</i> (g)	Intersecção entre a linha média facial e a linha horizontal que tangencia o bordo superior da circunferência orbitária.
2. <i>Nasion</i> (n)	Intersecção da linha média facial com a linha horizontal que passa pelo sulco palpebral superior.
3. <i>Subnasale</i> (sn)	Ponto mais inferior da columela (projeção que se encontra entre as narinas).
4. <i>Labiale superius</i> (ls)	Ponto médio da linha branca do lábio superior. Quando presente o arco de cupido, o ponto será marcado em seu ponto mais inferior.
5. <i>Stomion</i> (sto)	Ponto na região de encontro dos lábios superior e inferior, posicionado na metade da distância entre os <i>cheilions</i> .
6. <i>Labiale inferius</i> (li)	Ponto médio da linha branca do lábio inferior.
7. <i>Gnathion</i> (gn)	Ponto mais inferior do mento.
8. <i>Midnasal</i> (mid)	Ponto sobre a linha média da face, tendo por referência a altura dos <i>exocanthions</i> .
9. <i>Entocanthion</i> (en)	Ponto localizado no ângulo medial dos olhos, marcado no encontro das pálpebras superior e inferior.
10. <i>Exocanthion</i> (ec)	Ponto localizado no ângulo lateral dos olhos, marcado no encontro das pálpebras superior e inferior.
11. <i>Iridion laterale</i> (il)	Ponto mais lateral da circunferência iridiana.
12. <i>Iridion mediale</i> (im)	Ponto mais medial da circunferência iridiana.
13. <i>Pupil</i> (pu)	Ponto central da circunferência iridiana.
14. <i>Zygion</i> (zy)	Ponto mais lateral do contorno da face à altura dos ossos zigomáticos.
15. <i>Alare</i> (al)	Ponto mais lateral da asa do nariz.
16. <i>Gonion</i> (go)	Ponto sobre a linha de contorno facial, à altura do <i>stomion</i> .
17. <i>Cheilion</i> (ch)	Ponto localizado na comissura labial, em sua região mais lateral.
18. <i>Crista philtri</i> (cph)	Ponto alto da crista do arco de cupido, no local de chegada das colunas do filtro labial.

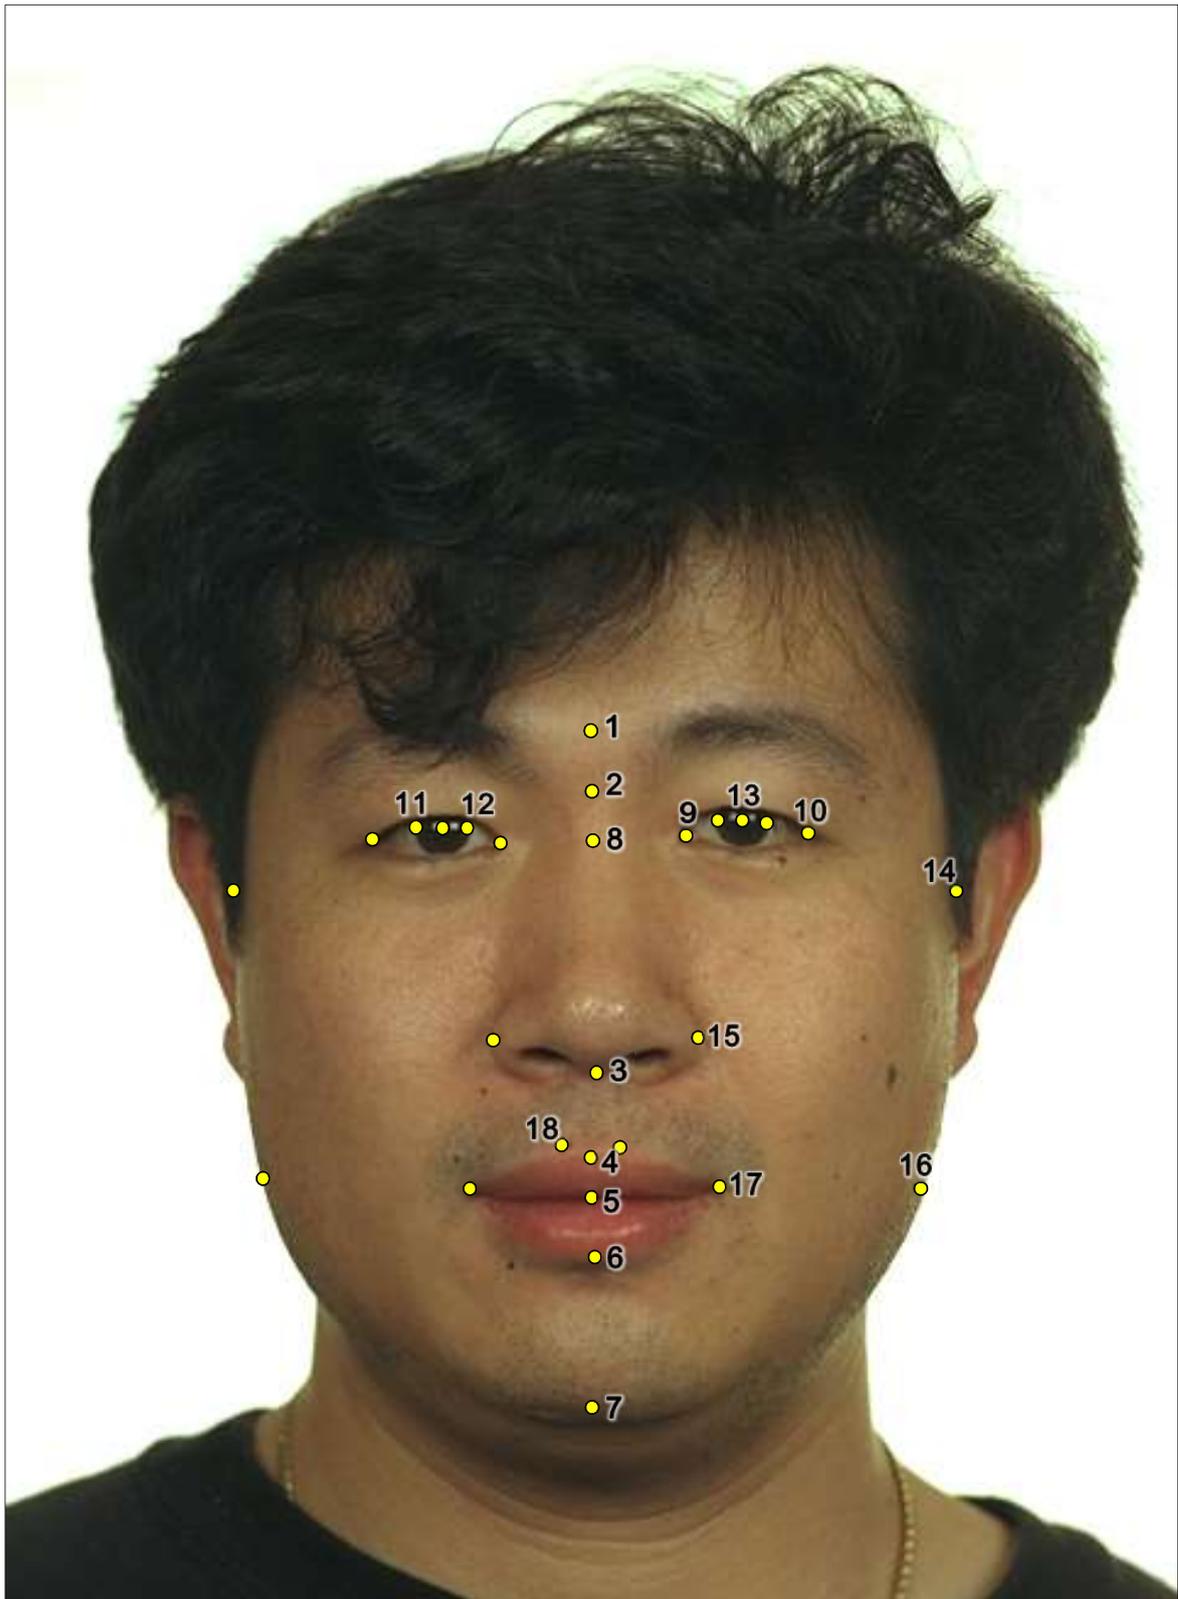


Figura 2.3: Representação gráfica da localização na face de todos os 28 pontos cefalométricos adotados neste trabalho: 1. *Glabella* (g); 2. *Nasion* (n); 3. *Subnasale* (sn); 4. *Labiale Superius* (ls); 5. *Stomion* (sto); 6. *Labiale Inferius* (li); 7. *Gnathion* (gn); 8. *Midnasal* (m); 9. *Endocanthion* (en); 10. *Exocanthion* (ex); 11. *Iridion Laterale* (il); 12. *Iridion Mediale* (im); 13. *Pupil* (pu); 14. *Zygion* (zy); 15. *Alare* (al); 16. *Gonion* (go); 17. *Cheilion* (ch); 18. *Crista Philtri* (cph), imagem adaptada de (PHILLIPS *et al.*, 2000).

a análise dos resultados Machado (2015) conseguiu separar matematicamente as dispersões em informações referentes às idades e o sexo em crianças e adolescentes. A partir dela, o autor confrontou seus resultados com o trabalho apresentado por Cattaneo *et al.* (2012). O resultado das correlações dos pontos apresentado em (CATTANEO *et al.*, 2012) não conseguiu separar determinados grupos de idade e sexo utilizando crianças e adolescentes, diferente da metodologia proposta em (MACHADO, 2015).

Os resultados demonstraram um avanço para as propostas na identificação do conteúdo da pornografia infantil (MACHADO *et al.*, 2014). Na Equação 2.2 é apresentada um vetor (V_i) com as quinze razões fotoantropométricas propostas em (MACHADO, 2015), em que i permite definir separadamente cada uma delas. Cada razão fotoantropométrica em V é um vetor definido pela Equação 2.2 utilizando determinados pontos cefalométricos, em que são utilizados o fator do tamanho da íris P_{iris} definido pela Equação 2.1.

Para cada variável existente na Equação 2.2 o nome e a localização são apresentados na Figura 2.3 enquanto a descrição detalhada é definida na Tabela 2.1. Os pontos em pares, estes existentes simetricamente nos dois lados da face, são definidos pelas informações “ d ” e “ e ”, distinguindo o ponto da face direita com o da face esquerda respectivamente, como exemplo podemos citar o ponto *Zygion* direito (zy_d) e o ponto *Zygion* esquerdo (zy_e).

$$V_i = \begin{bmatrix} (|zy_e - zy_d|)/P_{iris} \\ (|go_e - go_d|)/P_{iris} \\ (|ec_e - ec_d|)/P_{iris} \\ (|al_e - al_d|)/P_{iris} \\ (|ch_e - ch_d|)/P_{iris} \\ (|g - sn|)/P_{iris} \\ (|g - ls|)/P_{iris} \\ (|g - gn|)/P_{iris} \\ (|n - mid|)/P_{iris} \\ (|n - sn|)/P_{iris} \\ (|n - gn|)/P_{iris} \\ (|mid - sto|)/P_{iris} \\ (|mid - li|)/P_{iris} \\ (|sn - gn|)/P_{iris} \\ (|sto - gn|)/P_{iris} \end{bmatrix} \quad (2.2)$$

2.4 ESTIMAÇÃO AUTOMÁTICA DE IDADE E SEXO

Como citado no início deste capítulo, é possível a utilização de várias técnicas para a estimação de idade e sexo de indivíduos em aplicações forenses, lembrando que abordagens

utilizando imagens faciais em redes neurais não são pesquisas recentes (GOLOMB; LAWRENCE; SEJNOWSKI, 1990). Estudos apresentados em (KRISHAN *et al.*, 2016; CAPPELLA *et al.*, 2019) demonstram entre estas, o uso de técnicas forenses para estimação de idades e análises antropológicas utilizando análises de esqueletos. De forma semelhante apresentado na Seção 2.1 pesquisas em (LIANG *et al.*, 2019; TONG *et al.*, 2018) demonstraram utilização de imagens de raio-X do pulso estão sendo aplicadas em treinamento de redes neurais convolucionais para estimação automática de idade.

De acordo com Han, Otto e Jain (2013) os avaliadores humanos para estimação de idade utilizando imagens faciais obtiveram resultados do erro absoluto médio (do inglês: *Mean absolute error* - MAE), métrica detalhada na Equação 3.2, valores entre 4,7 e 7,2, sendo que a metodologia automática proposta por eles foi superior quando comparada com desempenho humano. Entretanto, Han, Otto e Jain (2013), descreveram que os avaliadores humanos obtiveram um resultado de MAE melhor que a abordagem automática para estimação de idade de indivíduos com idades de 0 a 15 anos. Enquanto no trabalho em (ANDA *et al.*, 2018) relata-se a habilidade dos seres humanos em estimar a idade de outras pessoas por meio de uma análise visual. Ainda neste trabalho Anda *et al.* (2018) apresentaram uma taxa de erro avaliada entre 2,07 até 8,62 anos de idade, dependendo de uma variedade de fatores, incluindo por exemplo a idade do avaliador.

Pesquisas relatam que a idade dos indivíduos jovens tende a ser consistentemente superestimada (PITTINGER; SHAW, 1975; HENSS, 1991; ROWE PAUL WILLNER, 2001) e em outros estudos demonstra a existência de assimilar a idade estimada com a própria idade (VESTLUND *et al.*, 2009; VOELKLE *et al.*, 2012). Neste contexto, no trabalho apresentado em (MOYSE; BRÉDART, 2012), foi constatado que dos 114 participantes obtiveram uma melhor precisão para estimar idade usando imagens faciais com o grupo pertencente à sua faixa etária, neste caso sendo 10 – 14, 20 – 30 e 65 – 75 anos de idade. Outros fatores influenciam o resultado do procedimento de estimação de idade usando imagens faciais por humanos, por exemplo expressões faciais (VOELKLE *et al.*, 2012; GANEL, 2015) e o sexo do indivíduo (VOELKLE *et al.*, 2012). Resumidamente expressões neutras resultam na maior precisão, enquanto qualquer outra expressão resulta em estimativas menos precisas (VOELKLE *et al.*, 2012).

Um dos grandes problemas para pesquisas em estimação automática de idade e sexo utilizando imagens faciais são as bases de dados públicas disponíveis. Nos trabalhos mais recentes do estado da arte comumente são utilizadas as seguintes bases para o desenvolvimento de metodologias automáticas: MORPH II (RICANEK; TESAFAYE, 2006), FG-NET (FU *et al.*, 2014) e AgeDB (MOSCHOLOU *et al.*, 2017). A base de dados faciais MORPH II dispõe mais de 55 mil imagens capturadas “*on-the-wild*” de 13.618 indivíduos, além da informação de idade que varia de 16 até 77 anos, esta também contém dados de sexo e ancestralidade. A base FG-NET (*The Face and Gesture Recognition Research Network*) contém 1.002 imagens coloridas e em escala de cinza de 82 indivíduos diferentes com idades va-

riando de 0 à 69 anos de idade. AgeDB contém 16.488 imagens faciais “*on-the-wild*” de 568 indivíduos com suas respectivas informações de idade e sexo. Os autores em (HAN *et al.*, 2017; WAN *et al.*, 2018; FANG *et al.*, 2019; THOMAZ; GIRALDI, 2010) adotaram diferentes bases para avaliar as metodologias propostas usando imagens faciais, onde neste caso temos como exemplo as bases CACD (CHEN; CHEN; HSU, 2015), CalebA (LIU *et al.*, 2015b), LFW+ (HUANG *et al.*, 2008), FEI (THOMAZ; GIRALDI, 2010), HOIP (FU; GUO; HUANG, 2010). Esta informação sobre a quantidade existente de bases de dados reforça o problema explanado anteriormente onde fica evidente a necessidade de padronização para métodos de avaliação de estudos utilizando imagens faciais.

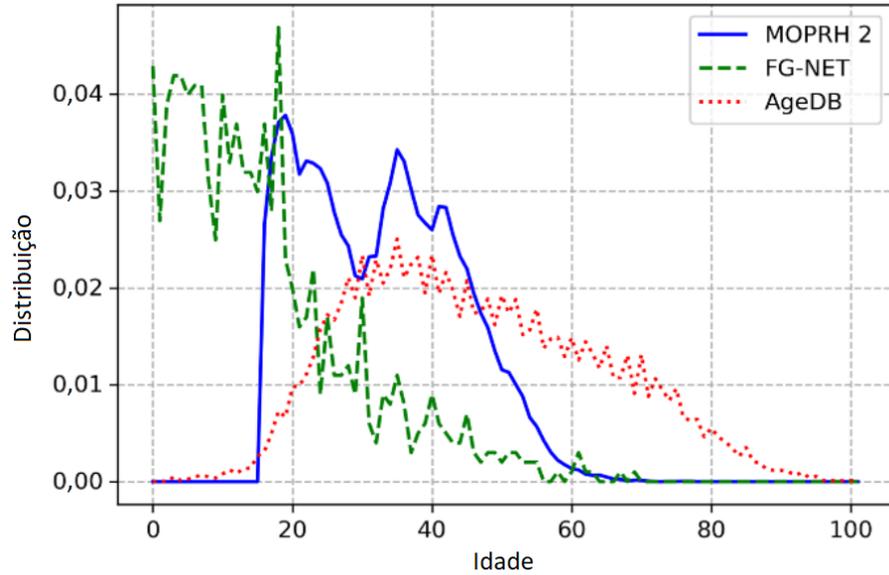
Mesmo a base MORPH II sendo amplamente utilizada desde 2006 em pesquisas (YIP *et al.*, 2018), como é possível observar, todas as bases supracitadas são desbalanceadas, tanto sobre as classes relativas à idade quanto sobre o sexo. Além disso, mesmo com mais de 55 mil imagens, como no caso da MORPH II, sendo de apenas um pouco mais de 13 mil indivíduos, onde temos 46.645 imagens de 11.459 indivíduos únicos do sexo masculino e 8.489 imagens de 2.159 indivíduos do sexo feminino. A Figura 2.4 (a) apresenta a distribuição da quantidade de imagens faciais nas três bases de dados por idade, enquanto a Figura 2.4 (b) apresenta a distribuição por sexo nas bases MORPH II, FG-NET e AgeDB. Os autores em (ANGULU; TAPAMO; ADEWUMI, 2018) descrevem sobre trabalhos relacionados à estimação de idade baseada em imagens faciais, neste é demonstrado que a base com mais indivíduos para este fim dispõe de 26.222 (UEKI; HAYASHIDA; KOBAYASHI, 2006) enquanto a base HOIP (FU; GUO; HUANG, 2010) é a que contém mais imagens, totalizando 306.600.

Em um trabalho recente, o autor em (ANDA *et al.*, 2018) relatou os problemas e as dificuldades com as bases existentes para fins forenses propondo uma base de dados de imagens faciais para estimação de idade e sexo para este fim. Ainda neste trabalho Anda *et al.* (2018) descrevem a base de dados VisAGe¹ que contém o total de 25.897 indivíduos com idades entre 0 e 19 anos sendo 11.940 do sexo masculino e 13.957 indivíduos do sexo feminino. A Figura 2.5 apresenta a distribuição das imagens entre idade e sexo da base de dados VisAGe.

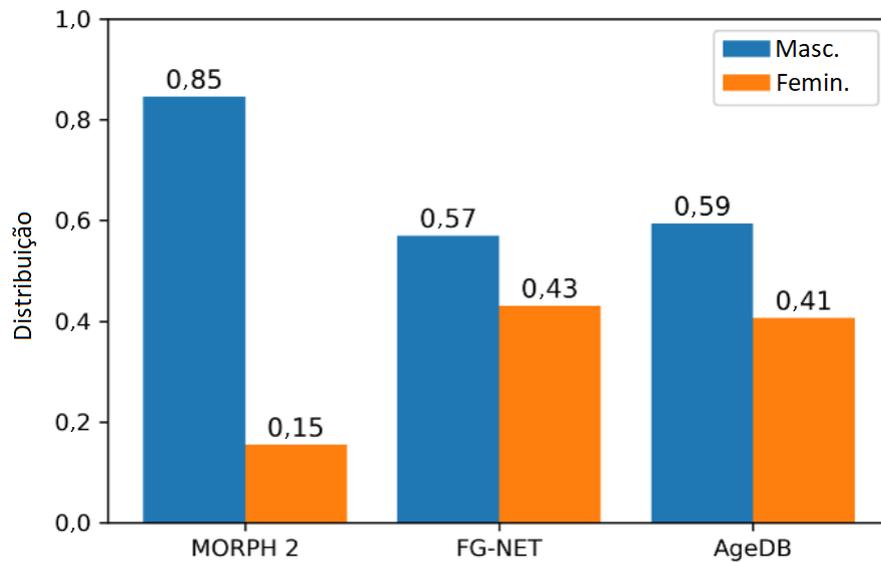
No estudo realizado em (DHIMAR; MISTREE, 2016), foi feita uma análise das metodologias existentes no estado da arte empregadas no desenvolvimento de abordagens para estimação automática de idade. Com isso Dhimar e Mistree (2016) apresentou como melhor solução geral a abordagem das CNNs citadas anteriormente, entretanto, o método antropométrico é apresentado como sendo um modelo básico, porém com resultados significativos em classificações para a estimação da idade em crianças e adolescentes.

Reforçando o que foi apresentado na Subseção 2.3.1, pesquisas apresentadas em (KWON; LOBO, 1994; BUSCHANG; TANGUAY; DEMIRJIAN, 1987) demonstram que a utilização dos pontos faciais e das distâncias dos elementos da face não é recente, estas já são utilizadas em técnicas de estimação de idade através de informações antropológicas. Entretanto,

¹Base de dados VisAGe disponível em: <https://www.forensicsandsecurity.com/visage.php>



(a) Representação gráfica da distribuição da quantidade de amostras por idade nas bases MORPH II, FG-NET e AgeDB.



(b) Representação gráfica da distribuição da quantidade de amostras por sexo nas bases MORPH II, FG-NET e AgeDB.

Figura 2.4: Distribuição de idade e sexo das bases de dados de imagens utilizadas em estudos para estimação de idade e sexo por meio de imagens faciais. Imagem adaptada de (XIE; PUN, 2019).

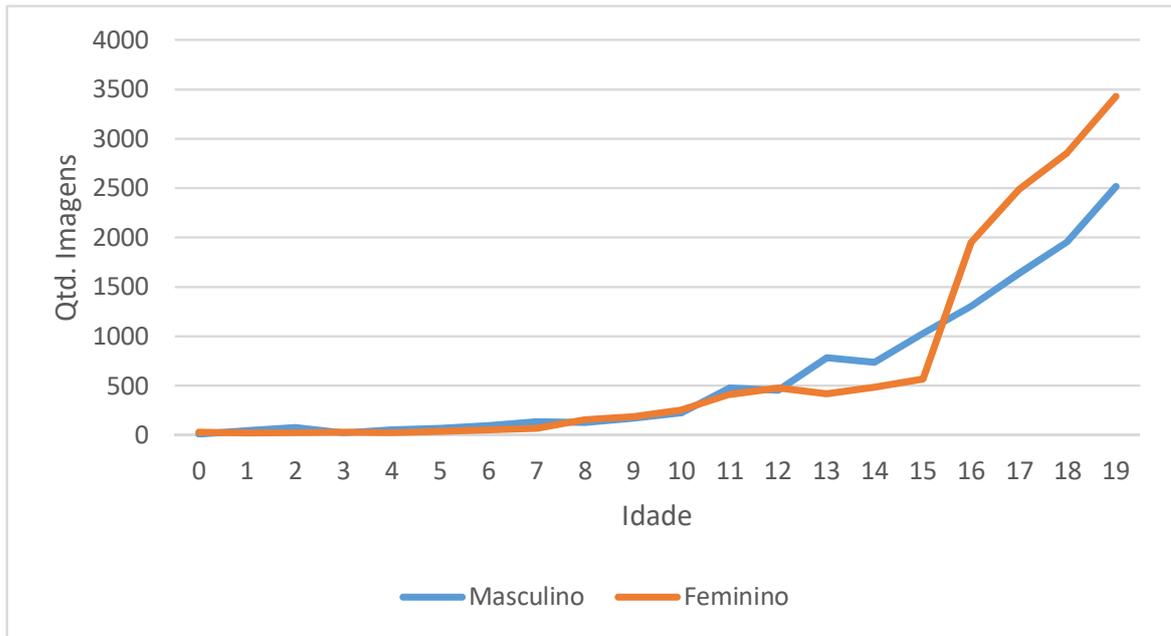


Figura 2.5: Representação gráfica da distribuição em idades e sexo das imagens da base de dados VisAGE.

o autor em (MACHADO, 2015) propôs uma nova metodologia, utilizando os pontos cefalométricos baseando-se no trabalho apresentado em (CATTANEO *et al.*, 2012), para estimar tanto a idade quanto o sexo. Enquanto isso, no estado da arte para estimação automática de idade e sexo, as pesquisas recentes demonstram resultados promissores no uso das CNNs para o uso em ambientes reais, como em (XIE; PUN, 2019; TAN *et al.*, 2017; XING *et al.*, 2017). Nos trabalhos apresentados em (TONG *et al.*, 2018; LIANG *et al.*, 2019) usando CNN para fins forenses também chamam atenção com resultados MAE próximos a zero (0,54 e 0,51), só que neste caso são adotadas imagens de raio-X do pulso dos indivíduos. Como descrito anteriormente a existência de diversas bases dados de imagens utilizadas para estimação de idade e sexo, sendo possível encontrar trabalhos com resultados utilizando bases privadas (LANITIS; TAYLOR; COOTES, 2002; SUO *et al.*, 2009; GUO *et al.*, 2009). A Tabela 2.2 apresenta resultados de diversos trabalhos de estimação de idade enquanto a Tabela 2.3 apresenta os resultados de pesquisas para estimação de sexo utilizando imagens faciais (ANDA *et al.*, 2019; ZHANG *et al.*, 2019; FANG *et al.*, 2019; TAHERI; TOYGAR, 2019).

No Capítulo 3 é apresentada a metodologia desenvolvida para a identificação dos pontos cefalométricos em imagens faciais de norma frontal bidimensionais e também, a metodologia desenvolvida para estimação de idade e sexo utilizando medidas fotoantropométricas. Ainda no Capítulo 3 são explanadas as informações relevantes sobre o funcionamento, a metodologia empregada no desenvolvimento e suas principais características.

Tabela 2.2: Resultados (MAE) comparativos entre as metodologias existentes no estado da arte para estimação automática de idade. (*) Porcentagem adotada como métrica para avaliar o estudo. (**) Datasets combinados (ANDA *et al.*, 2018).

MÉTODO	Base e Resultado (MAE)
(LANITIS; TAYLOR; COOTES, 2002)	Base privada: 4,3
(HAYASHI <i>et al.</i> , 2002)	Base privada: 27%*
(IGA <i>et al.</i> , 2003)	Base privada: 58,4%*
(GENG; ZHOU; SMITH-MILES, 2007)	MORPH: 8,8 FG-NET: 6,8
(FU; HUANG, 2008)	Base privada: 5,5
(SUO <i>et al.</i> , 2009)	FG-NET: 6,0 Base privada: 4,7
(GUO <i>et al.</i> , 2009)	FG-NET: 4,8 Base privada: Fem: 3,9 - Mas: 3,5
(HAN; OTTO; JAIN, 2013)	MORPH II: 4,2 FG-NET: 4,6 PCSO: 5,1
(XING <i>et al.</i> , 2017)	MORPH II: 2,96 WebFace: 5,75
(LI <i>et al.</i> , 2017)	MORPH II: 3,06 WebFace: 6,04
(TAN <i>et al.</i> , 2017)	MORPH II: 2,52 FG-NET: 2,96 CACD: 4,68
(HAN <i>et al.</i> , 2017)	MORPH II: 3,00 LFW+: 4,5
(WAN <i>et al.</i> , 2018)	MORPH II: 3,30 CACD: 5,22
(SHEN <i>et al.</i> , 2018)	MORPH II: 2,17 FG-NET: 3,85 CACD: 5,76
(RONDEAU; ALVAREZ, 2018)	IMDB-WIKI Idade aparente: 2,98 Idade Biológica: 5,43
(XIE; PUN, 2019)	MORPH II: 2,81 FG-NET: 3,58
(TAHERI; TOYGAR, 2019)	MORPH II: 2,81 FG-NET: 3,05
(FANG <i>et al.</i> , 2019)	Adience: 1,84 FG-NET: 2,69 CACD: 5,38
(ZHANG <i>et al.</i> , 2019)	MORPH II: 2,85 - FG-NET: 3,71
(ANDA <i>et al.</i> , 2019)	Datasets Combinados**: 2,42

Tabela 2.3: Resultados (%) comparativos entre as metodologias existentes no estado da arte para estimação automática de sexo.

MÉTODO	Base e Resultado (%)
(HAN; OTTO; JAIN, 2013)	MORPH II: 74,8% FG-NET: 74,8% PCSO: 64,0%
(XING <i>et al.</i> , 2017)	MORPH II: 98,7% WebFace: 92,3%
(HAN <i>et al.</i> , 2017)	MORPH II: 99,0% LFW+: 96,7%
(WAN <i>et al.</i> , 2018)	MORPH II: 97,82%
(SHEN <i>et al.</i> , 2018)	MORPH II: 91,3% FG-NET: 80,6%
(XIE; PUN, 2019)	MORPH II: 99,1% FG-NET: 92,3%
(FANG <i>et al.</i> , 2019)	Adience: 93,52% FG-NET: 98,8% CACD: 95,01%
(AFIFI; ABDELHAMED, 2019)	LFW+: 95,98% Adience: 90,59% FERET: 99,49%
(VERMA <i>et al.</i> , 2019)	Base Privada de Faces Indianas: 98,7%
(RANJAN <i>et al.</i> , 2017)	CelebA: 99%
(KHAN <i>et al.</i> , 2019)	Adiance: 91,4% FERET: 100% LFW+: 94,4% FEI: 93,7%

3 METODOLOGIA PROPOSTA

Neste capítulo é detalhada a metodologia utilizada neste trabalho. O primeiro passo foi o desenvolvimento de uma abordagem automática de identificação dos pontos cefalométricos em imagens faciais de norma frontal. Mesmo com a existência de ferramentas para tal propósito, pesquisas na área de fotoantropometria utilizando os pontos faciais necessitam de uma solução precisa, que reproduza os resultados automáticos semelhantes a um profissional da área obtidos manualmente. Tal necessidade permitiu o desenvolvimento de uma abordagem supervisionada com o objetivo de mensurar a acurácia das soluções automatizadas. Com a automatização da detecção e identificação dos pontos, permite-se implementar as razões fotoantropométricas existentes na literatura, juntamente com técnicas de inteligência artificial, auxiliando o processo de estimação de idade, sexo em imagens bidimensionais. Desta maneira, são apresentadas as metodologias propostas para a identificação automática dos pontos cefalométricos seguida da utilização das razões fotoantropométricas para estimação de idade e sexo. Na Figura 3.1 é apresentada a estrutura geral do trabalho desenvolvido dividida em três partes. A primeira parte está relacionada com a abordagem de estimação automática dos pontos cefalométricos. A segunda é o procedimento de estimação de idade e sexo utilizando uma rede neural artificial (do inglês *Artificial Neural Network* - ANN) usando como dado de entrada as razões fotoantropométricas, e por último a abordagem para estimação de idade e sexo combinando uma rede neural artificial (ANN) com uma rede neural convolucional (CNN) usando as fotoantropométricas e a imagem facial como dados de entrada das redes.

3.1 BASE DE DADOS DE IMAGENS FACIAIS

Para alcançar os objetivos propostos neste trabalho, tanto para identificar automaticamente os pontos cefalométricos em imagens faciais de norma frontal, quanto a serem utilizadas posteriormente para análises de fotoantropometria na determinação de idade e sexo é necessário descrever a base de imagens faciais adotada nesta pesquisa. Conforme apresentado anteriormente na Seção 2.4, um dos problemas para estudos utilizando imagens faciais são as bases de dados existentes disponíveis, podendo ser o problema relacionado com a quantidade de imagens, quantidade de indivíduos e problema relacionado com o balanceamento das bases. Este desbalanceamento na base de dados define a discrepância das classes a serem avaliadas, sendo a distribuição não homogênea das imagens por idades e também por sexo. De maneira semelhante as outras bases, a base utilizada neste trabalho é composta por imagens faciais, entretanto diferente das outras bases o conjunto de imagens empregado para treinar e testar os métodos automáticos propostos é composto apenas de imagens faciais de norma frontal.

Para cada etapa foi definida uma quantidade específica de imagens utilizadas no pro-

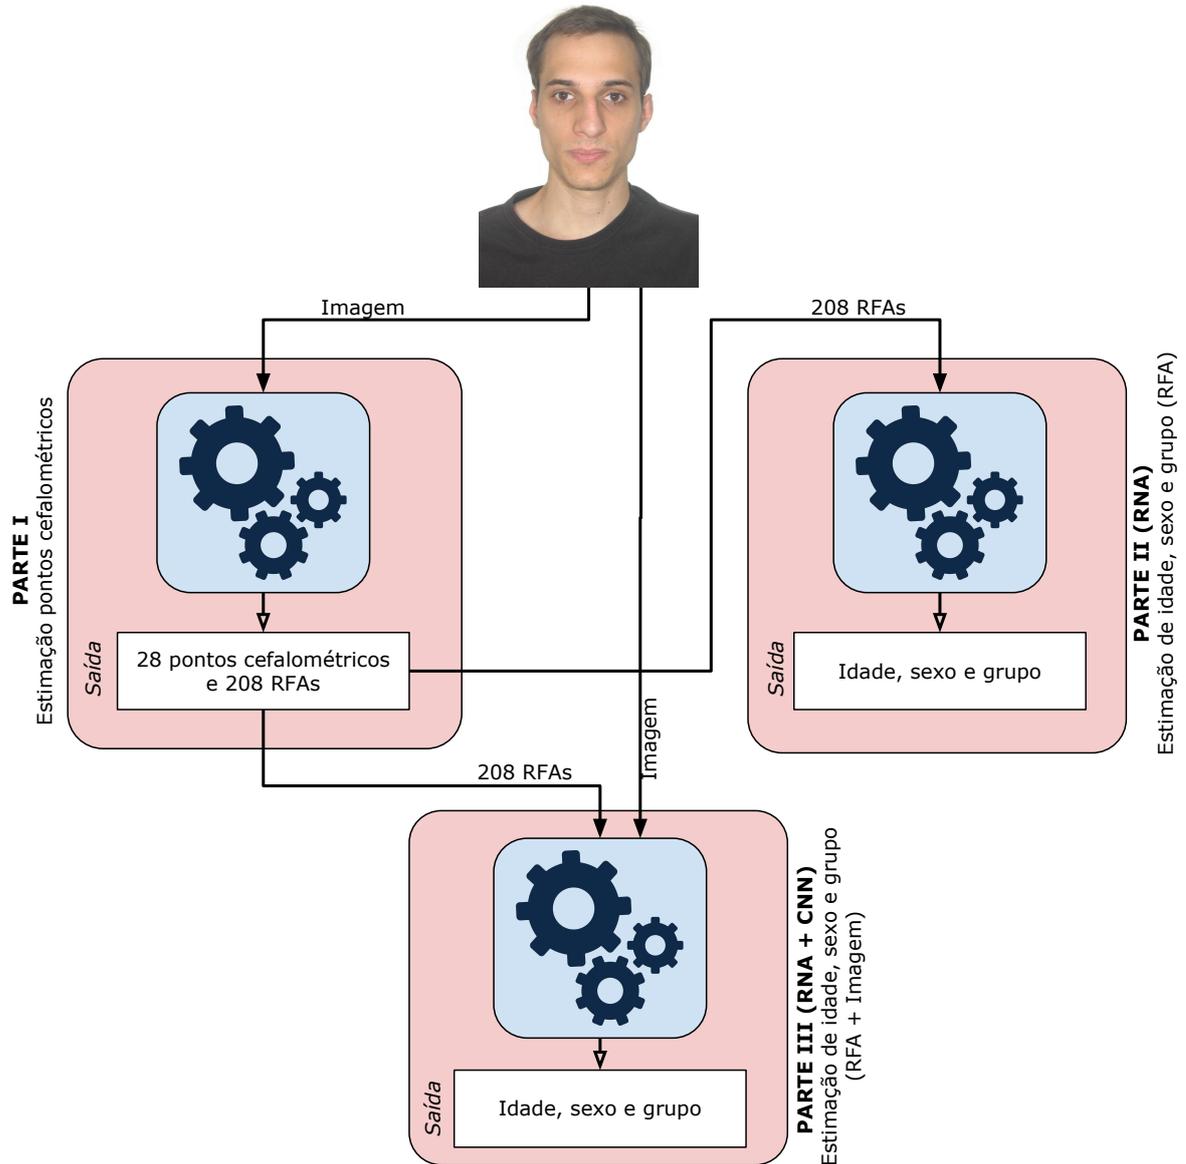


Figura 3.1: Fluxograma da proposta desenvolvida.

cesso de treinamento e teste. Na primeira etapa, foram adotadas imagens faciais de 1.000 indivíduos, a distribuição e as classes utilizadas são apresentadas detalhadamente na Subseção 3.2.2. Na segunda etapa foram definidas 18.000 imagens faciais, os detalhes desta base são descritos na Subseção 3.3.1, e na última etapa foram 105.000 imagens faciais, os detalhes desta são descritos na Subseção 3.4.1. Em todos os casos são imagens de faces frontais (uma imagem por indivíduo) que foram adquiridas cumprindo a normativa ICAO 9303 (International Organization for Standardization, 2005) para documentos internacionais de viagem, isto é, mesmo padrão adotado em passaportes. Foi usada uma configuração de câmera com um distância focal de $35mm$ e sendo o indivíduo posicionado a $1,5m$ de distância da câmera. As imagens foram armazenadas em uma resolução espacial de 480×640 pixels e 24 bits de profundidade. Todas as imagens capturadas foram obtidas sobre um fundo branco e uniforme, com expressão facial neutra e sem o uso de óculos. Os critérios de inclusão

são os mesmos adotados pelos autores em (FLORES, 2014; MACHADO, 2015) sendo eles: cidadãos brasileiros na faixa etária de 2 a 22 anos, com expressão facial neutra, lábios fechados e face posicionada diretamente em direção à câmera. Os critérios de exclusão foram indivíduos com evidente rotação da cabeça nos planos sagital, axial ou coronal; bem como indivíduos com deformidades faciais evidentes, assimetrias, pelos faciais, joias, maquiagem ou com uma área incompleta do rosto.

3.2 IDENTIFICAÇÃO AUTOMÁTICA DOS PONTOS CEFALOMÉTRICOS EM IMAGENS FACIAIS

A metodologia proposta para automatizar a localização dos pontos cefalométricos possui três componentes principais: pré-processamento da imagem, detecção das regiões da face e processo de treinamento dos pontos cefalométricos, conforme apresentado na Figura 3.2. Para cada entrada utilizando uma imagem facial é aplicada uma etapa de pré-processamento para realçar o contraste na imagem para reforçar características faciais. A partir dessas características, a técnica de detecção de rosto proposta por Viola e Jones (2004) é capaz de identificar regiões de interesse específicas, primeiro toda a face e, a partir dela, com a face detectada, é dividida nas seguintes regiões: olhos, boca e nariz. Finalmente, um método supervisionado baseado em regressão (HUBER *et al.*, 2015; XIONG; TORRE, 2015, 2013) é aplicado para cada uma das quatro regiões individuais detectadas no estágio anterior. Esta abordagem tem como objetivo criar classificadores especializados para cada região, diminuindo a área de busca dos pontos, consequentemente erros.

O processo de aprendizagem considera um grupo de imagens faciais rotuladas (veja a Subseção 3.2.2 para uma descrição detalhada abaixo), ou seja, um conjunto de imagens faciais juntamente com a localização (coordenadas x e y horizontal e vertical, respectivamente) dos pontos cefalométricos para cada imagem. Este processo de aprendizagem é baseado no algoritmo apresentado em (HUBER *et al.*, 2015). Esta abordagem proposta em (HUBER *et al.*, 2015) consiste em auxiliar o treinamento do algoritmo delimitando a área de busca na imagem, neste caso a região da face, para cada ponto gerando um classificador de pontos faciais.

Na metodologia proposta neste trabalho, os arquivos dos conjuntos de treinamento, neste caso os pontos cefalométricos, são agrupados por regiões de interesse. Como resultado, dentro da área face, são definidas regiões específicas responsáveis por um determinado grupo de pontos. Esta abordagem define criar classificadores especializados para cada região na face permitindo uma busca mais restrita dos seus respectivos pontos cefalométricos. Este sendo denominado por *Huber-Region* (**HR** de agora em diante). Na Figura 3.2 a metodologia **HR** é apresentada como o fluxo de execução do processo proposto, sendo possível visualizar a entrada de um conjunto de imagens para o treinamento, identificação das regiões de inte-

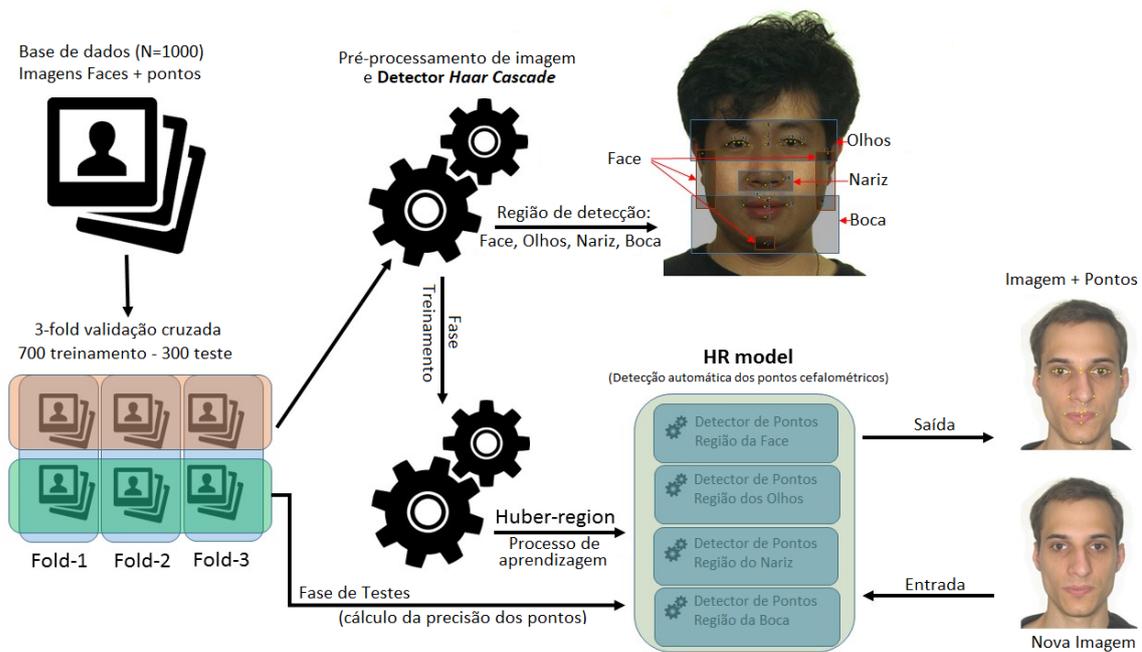


Figura 3.2: Representação gráfica da abordagem automática proposta do algoritmo. Inclui também a abordagem metodológica seguida para treinar o modelo de aprendizagem e validá-lo por meio da validação cruzada em três etapas.

resse na face e quando treinado, a busca dos pontos cefalométricos em cada classificador especializado a partir de uma imagem de entrada.

No restante desta seção, será apresentada e detalhada outras abordagens para localização automática de pontos faciais (Subseção 3.2.1), o conjunto de imagens e pontos cefalométricos usados neste trabalho (na Subseção 3.2.2) e finalmente a estrutura dos testes e as métricas utilizadas para validar a abordagem proposta. Por fim estudar sua confiabilidade comparando-a com as outras propostas automáticas e o desempenho de especialistas humanos (Subseção 3.2.3).

3.2.1 Outras abordagens de identificação automática de pontos faciais

Como explicado anteriormente, a localização automática de pontos faciais foi abordada na comunidade da área de Visão Computacional por mais de vinte anos. No entanto, a desvantagem comum que todas essas propostas compartilham é o conjunto de pontos faciais (do inglês *facial landmarks*) reconhecidos por esses algoritmos (LANITIS *et al.*, 1995). Eles não são pontos cefalométricos porque os pontos faciais reconhecidos não foram desenvolvidos para a análise de fotoantropometria, mas para rastreamento de face, estimativa de pose, reconhecimento de emoção, registro de face e reconhecimento, como descrito em (ÇELIK-TUTAN; ULUKAYA; SANKUR, 2013).

Entre os métodos de última geração, duas das abordagens mais populares são DLIB (KING, 2009) e *Supervised Descent* (SD) (HUBER *et al.*, 2015; XIONG; TORRE, 2013). Ambos

usam a técnica de histograma de gradientes orientados (HOG) (DALAL; TRIGGS, 2005) para identificar a característica de referência do ponto em uma posição específica na imagem. O DLIB usa o HOG em combinação com um classificador linear enquanto o SD combina o HOG com a posição espacial na face para cada ponto. Durante o processo de identificação em SD, o algoritmo começa a procurar a característica em uma região específica da imagem, tornando o processo rápido e evitando correspondências falso-positivas em outra região. Foi feito uso desses dois algoritmos (SD e DLIB), mas neste caso, os treinamentos foram com os mesmos conjuntos de imagens e pontos cefalométricos (consulte a Subseção 3.2.2) usados neste trabalho, para que fosse possível medir e comparar o desempenho das três abordagens automáticas nas mesmas condições.

3.2.2 Base de dados: imagens e pontos cefalométricos

O principal objetivo é identificar automaticamente os pontos cefalométricos em imagens faciais de norma frontal a serem utilizadas para análise de fotoantropometria. Assim, o conjunto de imagens empregadas para treinar e testar os métodos automáticos propostos é composto de imagens faciais frontais, onde 28 pontos cefalométricos, os mesmos descritos na Subseção 2.3.1, foram localizados manualmente por um perito da área. Em particular: são imagens de faces frontais de 1.000 indivíduos que foram adquiridas cumprindo a normativa ICAO 9303 (International Organization for Standardization, 2005) para documentos de viagem nas mesmas condições apresentadas na Seção 3.1. Das 105.000 imagens descritas no início deste capítulo, para o procedimento de estimação automática dos pontos foram utilizadas 1.000 amostras, onde estas foram distribuídas igualmente entre os sexos masculino (500 imagens) e feminino (500 imagens) para a classe de sexo e cinco classes etárias diferentes (6, 10, 14, 18 e 22 anos), cada faixa etária com 200 indivíduos, a mesma amostra descrita na Subseção 2.3.1 e utilizada nos trabalhos em (MACHADO, 2015; MACHADO *et al.*, 2017; BORGES *et al.*, 2018). Finalmente, também é discutido o processo de medir e avaliar a precisão em *pixels* da abordagem automática proposta em comparação com a dispersão da localização manual por especialistas. Para isso, foi adotado um conjunto de dados diferente, composto por 20 imagens, em que 12 especialistas forenses localizaram manualmente (estudo de dispersão entre especialistas) o mesmo conjunto de pontos cefalométricos usando o *software* descrito anteriormente na Subseção 2.3.1.

3.2.3 Experimento e métricas de avaliação

Conforme descrito na Seção 3.2, foi desenvolvido o processo de treinamento em quatro regiões específicas: face, olhos, boca e nariz. O conjunto completo de dados fotográficos possui 1.000 imagens faciais e 1.000 arquivos com os pontos cefalométricos de referência, cada um contendo as coordenadas x e y de cada um dos 28 pontos faciais.

Para avaliar o desempenho de um modelo baseado em regressão ou de classificador uti-

lizando um conjunto de dados, os esquemas de validação cruzada (*k-fold*) são comumente usados na literatura da área de aprendizagem de máquinas (HASTIE; TIBSHIRANI; FRIEDMAN, 2009; KOHAVI *et al.*, 1995). Neste caso, um procedimento de validação cruzada tripla ($k=3$) foi adotado, separando aleatoriamente três vezes 700 imagens para treinamento dos detectores e 300 imagens para teste. A Figura 3.2 anterior também representa a metodologia de validação por meio da validação cruzada.

Como resultado do processo de treinamento, foram gerados quatro detectores automáticos dos pontos cefalométricos: detector de pontos cefalométrico dos olhos (inclui *Glabella*, *Nasion*, *Midnasal*, *Endocanthion*, *Exocanthion*, *Iridion Laterale*, *Iridion Mediale* e *Pupil*), detector de pontos cefalométricos da boca (*Labiale Superius*, *Stomion*, *Labiale Inferius*, *Cheilion*, *Gonion*, *Gnathion* e *Crista Philtri*), detector de pontos cefalométricos da face (inclui *Zygion*, *Gonion* e *Gnathion*) e detector de pontos cefalométricos do nariz (inclui os pontos *Subnasale* e *Alare*).

Para quantificar a precisão do algoritmo, foi mensurada a distância Euclidiana em *pixels* entre a localização do ponto cefalométrico obtida pelos algoritmos automáticos e uma referência (ou ponto manual), ou seja, os pares de coordenadas (x, y) de cada ponto/imagem de acordo com procedimento manual seguido pelo especialista. A fim de permitir a comparação de erros (e agregação) ao longo de todos os casos (e o uso em trabalhos futuros na área), foi adotado um processo de normalização das distâncias euclidianas. Um procedimento como este é necessário ao comparar distâncias entre imagens de diferentes resoluções e parâmetros da câmera de aquisição (distância focal e sujeito à distância da câmera). Desta forma, a métrica de erro para um par específico de pontos (referência manual e o automático) é a distância euclidiana entre eles dividida pela distância euclidiana entre os dois pontos cefalométricos *Exocanthion*.

3.3 ESTIMAÇÃO AUTOMÁTICA DE IDADE E SEXO USANDO RAZÕES FOTOANTROPOMÉTRICAS

Nesta seção o objetivo principal é propor uma metodologia para estimação automática de idade e sexo com o uso de dados fotoantropométricos de uma face humana. Com as métricas faciais, geradas utilizando os pontos cefalométricos identificados automaticamente, espera-se aplicá-las em um classificador baseado em rede neural artificial para estimação automática de dados antropológicos. No decorrer do texto é apresentada a metodologia proposta para criar uma solução automática usando o modelo de Inteligência Artificial e os detalhes das entradas e dos testes.

3.3.1 Base de dados: imagens e pontos cefalométricos

De maneira semelhante à base de dados anterior, esta é composta por dados fotográficos das 18.000 imagens faciais de norma frontal de 18.000 pessoas diferentes do Brasil descritas na Seção 3.1. Relembrando, as imagens adquiridas são divididas em masculinos (9.000) e femininos (9.000) e 18 grupos etários (de 5 a 22 anos), totalizando 500 imagens para cada grupo individual (sexo e idade).

Os pontos cefalométricos adotados neste trabalho, todos usados para criar as razões fotoantropométricas, foram descritos em (MACHADO *et al.*, 2017) e (BORGES *et al.*, 2018). Nestas metodologias, como descrito anteriormente na Subseção 3.2.2, um especialista localizou manualmente 28 pontos cefalométricos em todas as 1.000 imagens (como as mesmas características de imagem descritas acima). Utilizando um *software* SAFF-2D definido como imagens pré-treinamento, aplicando uma metodologia de identificação proposta em (FLORES *et al.*, 2019; FLORES; MACHADADO, 2018; FLORES, 2014). Todas as 18.000 imagens faciais foram processadas gerando automaticamente os pontos cefalométricos e as razões fotoantropométricas seguindo a metodologia desenvolvida na seção anterior.

3.3.2 Razões fotoantropométricas

Utilizando os pontos cefalométricos detalhados na Subseção 2.3.1 os autores apresentaram em (MACHADO *et al.*, 2017) e (BORGES *et al.*, 2018) detalhes sobre 10 e 40 razões fotoantropométricas (RFAs) da face, respectivamente, como medidas faciais que permitiram descrever as informações antropométricas de pessoas utilizando apenas informações de crescimento facial, especificamente a idade e o sexo. De acordo com o autor em (MACHADO, 2015) a principal característica dessas RFAs é usar a média do diâmetro da íris como um fator proporcional, definido como **razão iridiana**, para resolver problemas de escala e calibração (por exemplo, relações de métricas sobre o tamanho do *pixel* e parâmetros intrínsecos do dispositivo de captura usado). Machado (2015) resumidamente, define que a razão iridiana ou tamanho da íris como a distância euclidiana definida por uma função $d(il, im)$ dos pontos *Iridion laterale* (*il*) e *Iridion mediale* (*im*) dos dois olhos (de uma borda a outra da íris), como descrito anteriormente na Subseção 2.3.2 pela Equação 2.1.

Utilizando a abordagem proposta para extrair automaticamente os pontos cefalométricos apresentada na Seção 3.2, foi aplicada essa metodologia (razão iridiana), combinando todos esses 28 pontos cefalométricos criando 208 índices RFAs. Como resultado, foi obtido um arquivo CSV com valores compostos pelos dados de fotoantropometria, incluindo 208 RFAs por imagem, rotulados por sexo e idade das 18.000 imagens usadas para construir o conjunto de dados. A descrição completa de todas as 208 RFAs é descrita no material suplementar da Apêndice B.

3.3.3 Experimentos e métricas de avaliação

Para executar todos os testes propostos foi utilizada a arquitetura de processamento on-line Intel AI DevCloud (APELAND,), um *framework* em nuvem para aplicações em Inteligência Artificial desenvolvido pela Intel, rodando a versão API Keras 2.2.0 (CHOLLET *et al.*, 2015) e Tensorflow versão 1.8 (ABADI *et al.*, 2015). No processo de treinamento, foi utilizado um modelo de rede neural artificial (ANN) baseado em *Multilayer Perceptron* (MLP) (RUMELHART; HINTON; WILLIAMS, 1985), usando uma camada densa (totalmente conectada) com 128 neurônios com o otimizador Adamax baseado em Adam (KINGMA; BA, 2014). A Tabela 3.1 apresenta a estrutura detalhada do modelo MLP utilizada para executar os testes.

Tabela 3.1: A estrutura detalhada da rede neural artificial usada para executar os testes.

# Camada de entrada	209 (208 RFAs + Sexo)
# Camada escondida	1
# Neurônios na camada escondida	128
# Épocas	500
Função de ativação na camada escondida	Sigmoid
Função de ativação na camada de saída	Softmax
Taxa de aprendizado	0.01
Momento	0.9
Otimizador	Adamax

Em um processo de classificação, todos os resultados precisam de uma análise de acurácia do teste e uma medida tradicional a ser usada é a pontuação F_1 score. Esta métrica de precisão é composta, por quatro parâmetros: Verdadeiro Positivo (n_{tp}), Verdadeiro Negativo (n_{tn}), Falso Positivo (n_{fp}) e Falso Negativo (n_{fn}). Ao final do processo de estimação, são avaliadas as informações estimadas como verdadeiras positivas (n_{tp}) quando o classificador atingiu corretamente os dados antropológicos (sexo e grupo etário) em relação aos dados de validação e como (n_{fp}) (falso positivo) quando o processo de classificação erra esses dados de validação (idade e grupo etário). É adotado o método de pontuação F_1 score mostrado na Equação 3.1, onde as variáveis *precision* e *recall* são definidas como $precision = n_{tp}/(n_{tp} + n_{fp})$ e $recall = n_{tp}/(n_{tp} + n_{fn})$, respectivamente. Todos os resultados da métrica F_1 score, após o processo de classificação, variam entre 1 (melhor) e 0 (pior). Para avaliar detalhadamente cada teste, é utilizado o método de matriz de confusão (PROVOST; KOHAVI, 1998), este modelo de avaliação de acurácia permite comparar cada “classe estimada” com o “classe verdadeira” resultando em uma tabela apresentando o resultado do comportamento do processo de classificação, este permite uma melhor visualização do comportamento global do classificador quando comparado com o valor de F_1 score.

$$F_1 = 2 * \left(\frac{precision * recall}{precision + recall} \right) \quad (3.1)$$

Para analisar a acurácia do processo de estimação de idade, em estudos com este fim, comumente adotam a métrica do erro absoluto médio (MAE), que também será adotado neste trabalho com o propósito de comparação com outras abordagens existentes no estado da arte. MAE é a medida da diferença absoluta de dois valores contínuos em um mesmo escopo, neste caso idades. No exemplo em questão, considere x e y como variáveis na mesma observação, onde x_i é a idade estimada automaticamente e y_i a idade real para aquele indivíduo i . Considerando que o experimento dispõe de N indivíduos, a equação de MAE resulta na diferença absoluta entre x_i e y_i de todos os indivíduos (N). Quanto menor o valor de MAE, onde 0 é o melhor resultado, significa que o valor estimado da idade (x_i) está o mais próximo da idade real (y_i), esta sendo definida pela Equação 3.2.

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - x_i|. \quad (3.2)$$

A fim de avaliar o desempenho esperado do modelo de classificação sobre o conjunto de dados proposto, uma validação cruzada k -fold foi utilizada para o processo de teste (HASTIE; TIBSHIRANI; FRIEDMAN, 2009; KOHAVI *et al.*, 1995). Para este estudo, um procedimento de validação cruzada de dez vezes ($k=10$) foi adotado, separando aleatoriamente nosso conjunto de dados dez vezes com 90% das imagens para treinamento dos classificadores e 10% das imagens para teste.

Para avaliar a metodologia das RFAs sobre a estimativa de dados antropológicos, foram definidos 3 grupos de testes. O primeiro, o **Grupo A** com o objetivo de estimar o sexo, o segundo, o **Grupo B**, para estimar a idade e o **Grupo C** para estimar a faixa etária, esses testes são descritos a seguir:

- **Grupo A - Estimação de sexo:** O grupo é composto por dois conjuntos de testes. O primeiro teste foi avaliado o processo de estimação de sexo em cada faixa etária separadamente totalizando 17 experimentos. No segundo é realizado um único experimento para estimar o sexo utilizando todas as amostras independente da idade.
- **Grupo B - Estimação de idade:** Este grupo é composto por 4 testes para avaliar a estimativa de idade usando os dados das RFAs. Todos os testes tiveram como objetivo identificar se a informação do sexo pode melhorar (ou interferir) na estimação de idade usando os índices faciais.
- **Grupo C - Estimação grupo de idade:** Neste grupo foram propostos dois classificadores, para avaliar se as medidas faciais são capazes de identificar se um indivíduo pertence a uma faixa etária específica. Neste caso, destinada a analisar o limiar de 14 e 18 anos. O primeiro, se for maior de 14 anos (consentimento sexual) e o segundo, se tiver mais de 18 anos (maior idade no sistema judicial).

Como listado anteriormente, o **Grupo A** é responsável por analisar a estimativa do sexo.

A Tabela 3.2 apresenta a estrutura dos testes do Grupo A. No Teste 1, o classificador foi treinado separadamente para cada faixa etária, totalizando 17 testes individuais de 5 a 22 anos. Este teste foi desenvolvido para avaliar o processo de classificação aplicado em cada faixa etária usando apenas os dados das RFAs. No Teste 2 foram utilizados todos os dados (desconsiderando as informações de idade) para avaliar a classificação sexo em todos os grupos etários de uma maneira geral.

Tabela 3.2: Grupo A: Estrutura dos testes para estimação de sexo.

Teste	Alvo	Idade como Entrada	Qtd. Testes
1	Sexo	Sim	17
2	Sexo	Não	1

Entretanto, no **Grupo B** sobre o processo de estimação de idade, a Tabela 3.3 apresenta a estrutura dos testes do Grupo B. Foram definidos 4 testes para avaliar o processo de classificação para estimativa de idade usando os dados das RFAs, em cada teste foi observado se a interferência da informação do sexo sobre o processo de estimação de idade.

Tabela 3.3: Grupo B: Estrutura dos testes para estimação de idade.

Teste	Alvo	Sexo como entrada
1	6,7,8,9,10,11,12,13,14,15,16,17,18,19,20,21,22	Não/Feminino/Masculino
2	6,8,10,12,14,16,18,20,22	Não/Feminino/Masculino
3	6,10,14,18,22	Não/Feminino/Masculino
4	5,10,15,20	Não/Feminino/Masculino

Resumindo, em cada teste proposto, foi treinado um classificador individual dividindo os dados das RFAs por sexo (feminino e masculino) e outro teste usando todos os dados no mesmo processo de classificação. Esses 4 testes do **Grupo B** são descritos a seguir:

- Teste 1: Foram selecionados os dados das RFAs de 6 a 22 anos em intervalos de 1 ano. Este teste teve como objetivo avaliar a precisão do classificador em relação à estimativa de idade, totalizando 17 classes de idade como saída.
- Teste 2: Foram adotados os dados das RFAs de 6 a 22 anos em intervalos de 2 anos. Este teste, como no Teste 1, o objetivo foi avaliar a acurácia do classificador em relação à estimativa de idade, totalizando como saída 9 classes idades: 6, 8, 10, 12, 14, 16, 18, 20 e 22.
- Teste 3: Foram utilizados os dados das RFAs de 6 a 22 anos em intervalos de 4 anos. Como semelhante ao acima, este avaliou a precisão do classificador em relação à estimativa de idade, totalizando como saída 5 classes de idades: 6, 10, 18 e 22.
- Teste 4: Foram selecionados os dados de RFA de 5 a 20 anos em intervalos de 5 anos e após todos os testes anteriores, este tem como objetivo em avaliar a precisão do

classificador em relação à estimativa de idade, totalizando como saída 4 classes: 5, 10, 15 e 20.

Por fim, no **Grupo C**, a Tabela 3.4 apresenta a estrutura dos testes da classificação por faixa etária, com limiar de 14 e 18 anos. Neste grupo de teste, foi avaliado se as RFAs podem ser usadas para estimar se a pessoa pode ser menor/maior de 14 anos ou menor/menor de 18 anos de idade. Foi adotado o mesmo procedimento de teste apresentado no **Grupo B**. Nesse caso, avaliando se a informação de sexo sobre o processo de estimativa de grupo etário, assim, para ambos os casos, foram testados para sexo feminino e masculino, desconsiderando a informação sobre sexo como entrada do classificador.

Tabela 3.4: Grupo C: Grupo de idade, estrutura dos testes de limiar de idade para 14 e 18 anos.

Teste	Alvo	Sexo como entrada
1	Menor/Maior de 14 anos	Não/Feminino/Masculino
2	Menor/Maior de 18 anos	Não/Feminino/Masculino

3.4 ESTIMAÇÃO AUTOMÁTICA DE IDADE E SEXO USANDO IMAGENS FACIAIS E RAZÕES FOTOANTROPOMÉTRICAS

Como apresentado na Subseção 2.4 os recentes trabalhos utilizando redes neurais convolucionais (CNN) em análises faciais demonstram potencial em aplicações para estimação de idade e sexo. Nesta seção é proposta uma metodologia para o treinamento de um modelo de uma rede neural convolucional com as imagens faciais de norma frontal com o intuito de comparar esta com a abordagem de estimação de sexo e idade utilizando as mesmas abordagens de avaliação aplicadas nas RFAs descritas na Seção 3.3, também apresentar uma abordagem que combina uma rede neural convolucional (imagens faciais) com uma rede neural artificial (RFAs).

3.4.1 Base de dados: imagens faciais

Para esta etapa do trabalho, a base de dados é composta por 105.000 imagens faciais de 105.000 pessoas diferentes e também, todas as imagens foram adquiridas de acordo com o normativo ICAO 9303 (International Organization for Standardization, 2005) usado em documentos de passaportes obedecendo todas as características descritas nas outras abordagens. Entretanto, nesta nova abordagem, as imagens utilizadas são divididas em masculinos (52.500) e femininos (52.500) e 21 grupos etários (de 2 a 22 anos), que abrange mais idades e, totalizando 2.500 imagens para cada grupo individual (sexo e idade). Por fim foi utilizada a abordagem de extração automática dos pontos cefalométricos nas imagens para gerar os

dados com as informações das RFAs para cada imagem como descrito anteriormente na Seção 3.2 e na Seção 3.3. Com estas características esta base de dados de imagens utilizadas nesta etapa do trabalho, além de ter uma quantidade significativamente maior de imagens e indivíduos, também dispõe de estar completamente balanceada no que se refere à informação de sexo e idade diferente das demais apresentadas na Subseção 2.4.

3.4.2 Experimentos e métricas de avaliação

Para estes experimentos foi adotado um modelo de uma rede neural convolucional com uma arquitetura definida, treinada e seus pesos (via *transfer learning*) utilizando uma base de dados para reconhecimento facial chamada de VGGFace (PARKHI *et al.*, 2015). Este processo permite executar um novo treinamento com uma rede neural convolucional treinada com outra base. Este procedimento auxilia a generalização da rede (aprendizado) para as novas imagens além de agilizar o processo diminuindo o tempo de treinamento. Para os experimentos foi adotada a versão API Keras 2.2.0 (CHOLLET *et al.*, 2015) e Tensorflow versão 1.8 (ABADI *et al.*, 2015). No processo de treinamento, foi utilizado um modelo de rede neural convolucional (CNN) baseado na arquitetura Resnet-50 (HE *et al.*, 2016) modificada para análises faciais com VGGFace (CAO *et al.*, 2018).

Como trabalhos recentes utilizam apenas as imagens como entrada para o processo de estimação de idade e sexo, como apresentado anteriormente na Seção 2.4, este trabalho também apresenta além da abordagem que utiliza as imagens em uma rede neural convolucional (CNN), uma abordagem que combina as imagens com as métricas faciais apresentadas anteriormente (RFAs) na Seção 3.3. Para avaliar se o modelo combinando imagens faciais e as RFAs alcançou algum ganho nos resultados, os testes foram divididos em: modelo utilizando apenas imagens (CNN) e modelo combinado utilizando imagens (CNN) e RFAs (ANN). A Figura 3.3 apresenta a estrutura do modelo proposto combinando imagem e as razões fotoantropométricas.

A fim de avaliar o desempenho esperado do modelo de classificação sobre o conjunto de dados proposto, também foi adotada a metodologia de validação cruzada *k-fold* (HASTIE; TIBSHIRANI; FRIEDMAN, 2009; KOHAVI *et al.*, 1995). Para este estudo, um procedimento de validação cruzada de cinco partes ($k=5$) foi adotado, separando aleatoriamente nosso conjunto de dados cinco vezes com 80% das imagens para treinamento dos classificadores e 20% das imagens para teste, onde para cada classe (sexo e idade) 2.000 imagens foram utilizadas para treinar e 500 para avaliar. Nos dois testes supracitados, é aplicada a mesma estrutura de avaliação apresentada na Subseção 3.3.3: estimação de idade (neste caso variando de 2 a 22 anos), sexo e grupo de idade. Ao utilizar os mesmos procedimentos de avaliação, estes permitem comparação da abordagem de estimação utilizando as RFAs com o modelo baseado em redes neurais convolucionais (imagens) e também com o modelo baseado na abordagem combinada (imagem e RFAs).

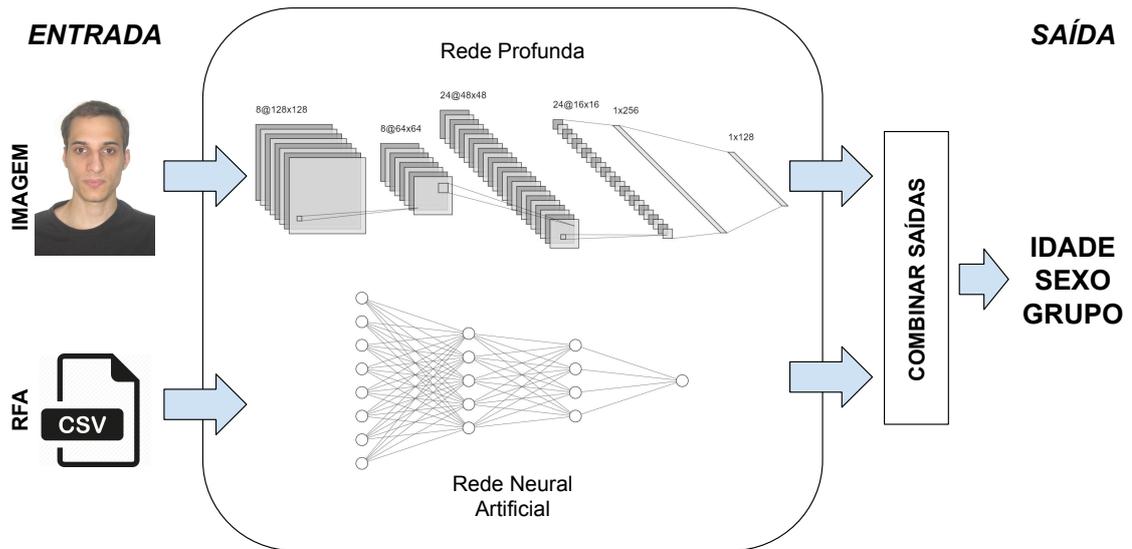


Figura 3.3: Exemplo da representação gráfica do modelo combinando uma rede neural convolucional com uma rede neural artificial para o treinamento utilizando como entrada da rede imagens faciais e as razões fotoantropométricas.

No próximo capítulo são apresentados os testes e resultados alcançados com as técnicas de Processamento de Imagens, Visão Computacional e Aprendizagem de máquinas implementadas nas metodologias apresentadas e propostas neste capítulo.

4 RESULTADOS

Neste capítulo são apresentados os testes e os resultados das abordagens principais deste trabalho, a identificação automática dos pontos cefalométricos descrita na Seção 3.2 e a estimação automática de dados antropológicos baseados em medidas fotoantropométricas em imagens faciais apresentadas na Seção 3.3 e na Seção 3.4.

4.1 IDENTIFICAÇÃO AUTOMÁTICA DOS PONTOS CEFALOMÉTRICOS EM IMAGENS FACIAIS

Os testes e análises realizados no protótipo desenvolvido seguem a metodologia apresentada no Capítulo 3. Vale ressaltar que todos os testes a seguir foram realizados utilizando a base de dados apresentada na Subseção 3.2.2. Com o desenvolvimento de um protótipo computacional funcional, os testes a seguir apresentam os resultados da aplicação que tem como objetivo principal, replicar automaticamente e incluindo também, a precisão, das marcações coletadas manualmente por especialistas da área.

Primeiramente, foi realizada uma análise comparativa entre o algoritmo proposto e outras duas abordagens automáticas da literatura, DLIB (KING, 2009) e SD (HUBER *et al.*, 2015; XIONG; TORRE, 2013). De acordo com a Subseção 3.2.3, cada algoritmo foi testado em 900 imagens (três conjuntos de teste compostos de 300 imagens cada) com 28 pontos de referência em cada teste. Para conjunto de marcações individual/imagem, foram utilizados no total 25.200 pontos cefalométricos, onde foi calculada a Distância Euclidiana (em *pixels*) entre a localização identificada por cada algoritmo automático e a localização fornecida pelo especialista (*referência correta*). Usando o valor resultante (erro de distância) foi classificado cada algoritmo de melhor desempenho para pior e finalmente foi calculada a classificação média, apresentada na Tabela 4.1. De acordo com a classificação média, o algoritmo proposto (HR) claramente supera as outras duas abordagens automáticas: 1 contra 2, 1 (SD) e 2, 9 (DLIB).

Tabela 4.1: Erro médio normalizado da distância em *pixels* por algoritmo.

	Algoritmo	Erro médio normalizado
1	HR	1,0
2	SD	2,1
3	DLIB	2,9

Para avaliar o teste de significância estatística do ranking dos algoritmos descritos anteriormente na Tabela 4.1, foi realizado o teste não paramétrico Wilcoxon Signed (KIM; KIM, 1996) usando todos os 25.200 valores (de precisão) para cada algoritmo. O resultado foi

o mesmo P -value de 7.6×10^{-6} para a HR contra SD e HR contra DLIB, o que certifica estatisticamente o desempenho superior da HR.

Olhando mais de perto para o desempenho do algoritmo, a Tabela 4.2 mostra a distância média de cada abordagem automática para cada ponto cefalométrico. Como esperado, a HR se desempenha sempre melhor que SD e DLIB, com grandes diferenças na maioria dos casos. O erro de distância média da HR encontra-se entre 0,010 e 0,019 para todos os pontos de referência (especialista), entretanto para ambos os *Zygion*, onde o erro aumenta para 0,031.

Tabela 4.2: Distância média do erro em *pixels*: análise das abordagens automáticas por ponto cefalométrico.

Landmark	Algoritmo	Distância Média	Landmark	Algoritmo	Distância Média
al	HR	0,012	ch	HR	0,014
	SD	0,027		SD	0,029
	DLIB	0,177		DLIB	0,024
cph	HR	0,014	ex	HR	0,013
	SD	0,024		SD	0,023
	DLIB	0,027		DLIB	0,028
en	HR	0,019	g	HR	0,012
	SD	0,029		SD	0,026
	DLIB	0,139		DLIB	0,168
gn	HR	0,012	go	HR	0,011
	SD	0,020		SD	0,019
	DLIB	0,035		DLIB	0,027
il	HR	0,012	im	HR	0,015
	SD	0,019		SD	0,025
	DLIB	0,052		DLIB	0,034
li	HR	0,016	ls	HR	0,012
	SD	0,025		SD	0,023
	DLIB	0,032		DLIB	0,165
m	HR	0,012	n	HR	0,015
	SD	0,021		SD	0,026
	DLIB	0,143		DLIB	0,035
pu	HR	0,010	sn	HR	0,010
	SD	0,022		SD	0,022
	DLIB	0,163		DLIB	0,154
sto	HR	0,010	zy	HR	0,031
	SD	0,021		SD	0,055
	DLIB	0,158		DLIB	0,161

Em segundo lugar, também é necessário medir a precisão das abordagens automáticas com foco especial na metodologia proposta (HR), com a abordagem automática de melhor desempenho, para realizar comparação com a dispersão da localização manual do especialista. Para isso, foi utilizado um conjunto de dados diferente, composto por 20 imagens, em que 12 especialistas forenses localizaram manualmente os pontos cefalométricos realizando um estudo de dispersão “entre especialistas” (*inter observer*), do mesmo conjunto de pontos

cefalométricos usando o *software* de marcação manual. A Tabela 4.3 mostra, na primeira linha, a distância média do erro normalizado dos 12 peritos forenses no conjunto reduzido de 20 imagens. As linhas seguintes referem-se à distância média do erro normalizado das três abordagens automáticas.

Tabela 4.3: Resultado geral: Especialistas (*inter observer*) vs abordagens automáticas. Um menor valor representa que os pontos cefalométricos estão concentrados próximos uns dos outros, significando uma melhor acurácia.

	Algoritmo	Distância Média
1	Especialista	0,009
2	HR	0,014
3	SD	0,026
4	DLIB	0,101

A distância média do erro normalizado dos 12 peritos forenses é de 0,009, enquanto o erro médio da abordagem proposta (HR) é de 0,014. O desempenho SD (0,026) e especialmente DLIB (0,101) está longe dos dois anteriores.

Na Figura 4.1 (pontos cefalométricos mediais) e na Figura 4.2 (pontos cefalométricos laterais), são apresentados os diagramas de caixa (*Box-plot*) que resumem o desempenho das três abordagens automáticas, sobre o conjunto de dados de testes com 900 imagens contra análise da dispersão no conjunto de dados reduzido de 20 imagens dos testes “entre especialista” (*inter observers*), neste caso os 12 peritos forenses. Embora a comparação entre abordagens automáticas e dispersão “entre especialistas” seja baseada em diferentes conjuntos de dados (900 x 20), ela nos permite ver quão próxima a abordagem automática proposta está da dispersão entre especialistas forenses.

Finalmente, a Figura 4.3 permite uma comparação visual dos resultados do método proposto (HR) contra a variabilidade entre especialistas. Na imagem, é apresentada a distribuição espacial dos pontos cefalométricos avaliados em todas as fotos do conjunto de dados. O tamanho e a forma geométrica da área ao redor de cada ponto facial mostram a precisão do ponto cefalométrico localizado pelo algoritmo proposto (à direita) e a variabilidade entre as marcações manuais pelos especialistas (à esquerda). Embora a variabilidade entre especialistas seja menor, a localização automática é visualmente similar e o erro geral é muito pequeno, se comparado ao tamanho da face.

4.2 ESTIMAÇÃO AUTOMÁTICA DE IDADE E SEXO USANDO RAZÕES FOTO-ANTROPOMÉTRICAS

Nesta seção são apresentados os testes e análises realizados no protótipo desenvolvido para a estimação de informações de idade e sexo utilizando as razões fotoantropométricas faciais (RFA) e também testes com imagens faciais com redes neurais profundas seguindo a

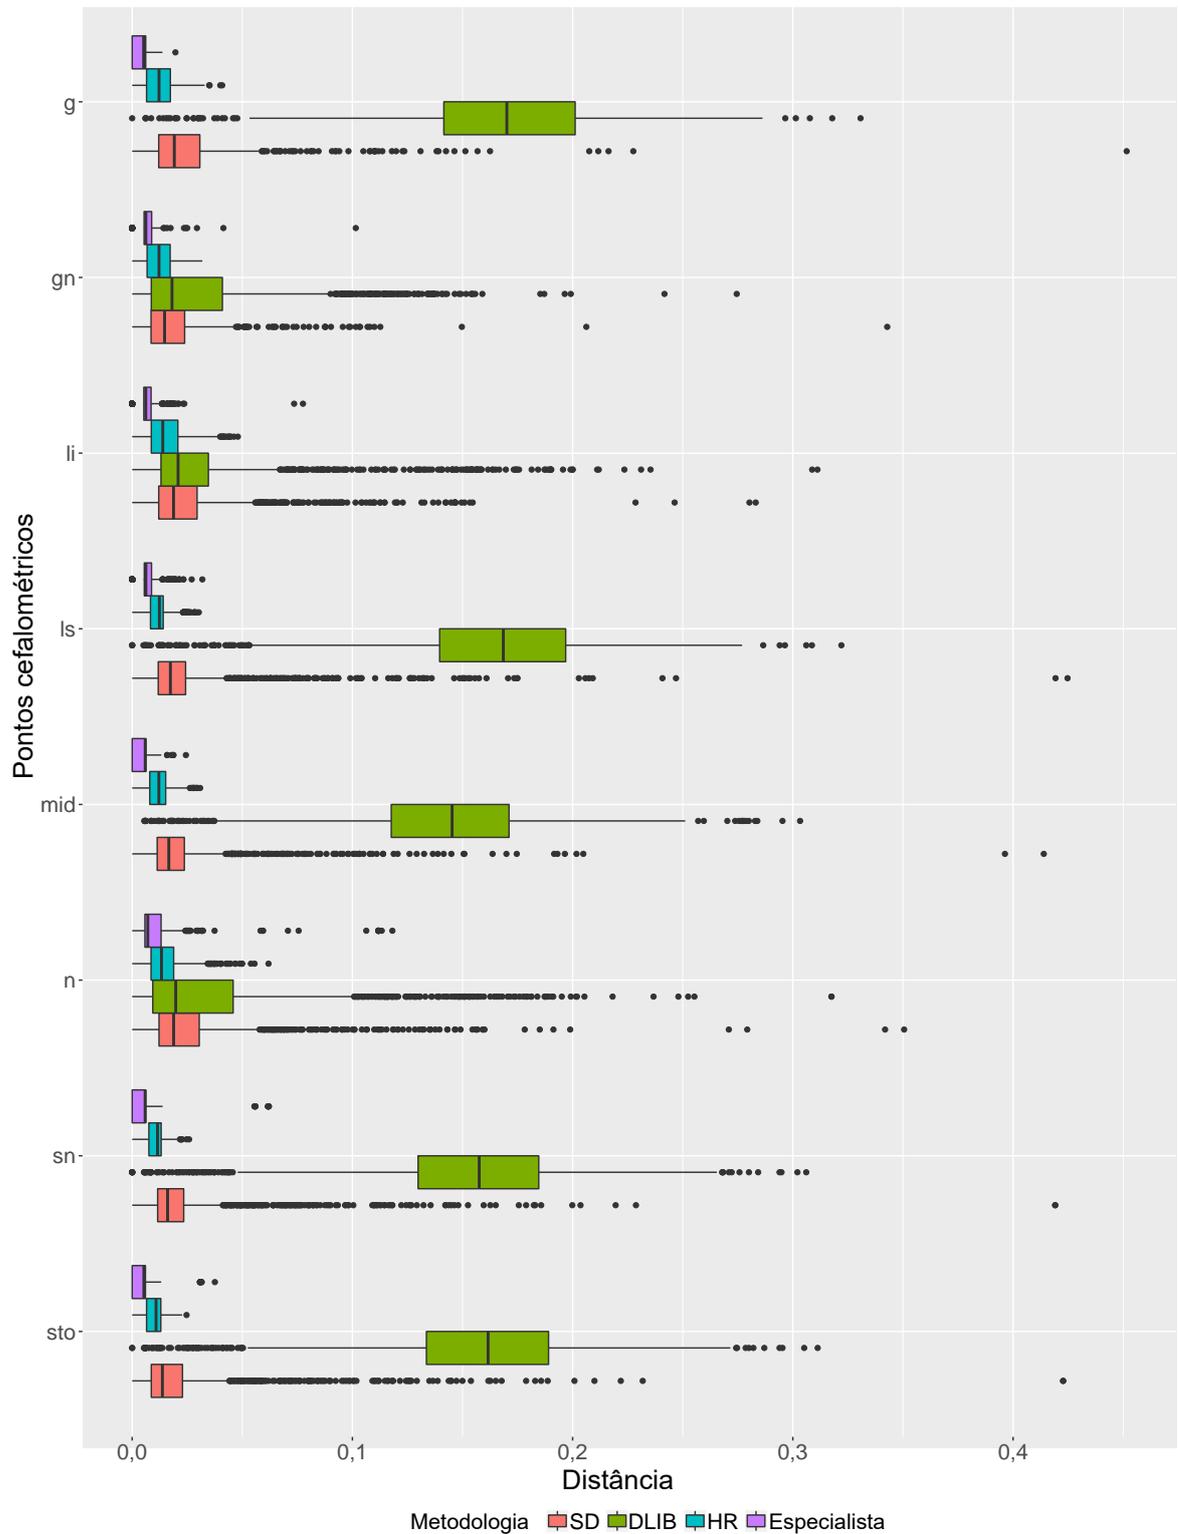


Figura 4.1: Diagrama de caixa (*Box-plots*) para cada ponto cefalométrico medial e por cada abordagem (os três algoritmos automáticos e a dispersão “entre especialistas”).



Figura 4.2: Diagrama de caixa (*Box-plots*) para cada ponto cefalométrico lateral e por cada abordagem (os três algoritmos automáticos e a dispersão “entre especialistas”).

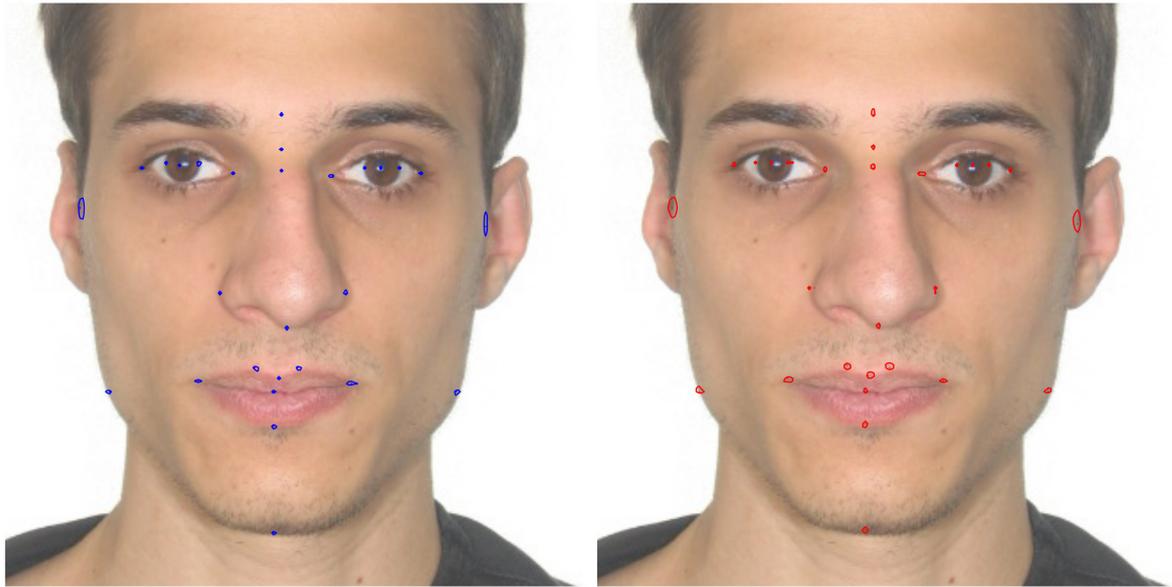


Figura 4.3: A distribuição espacial normalizada das marcações realizada pelos vinte especialistas (esquerda) e a abordagem automático proposta (direita).

metodologia apresentada no Capítulo 3.

Aqui são apresentados os testes e análises realizados no protótipo desenvolvido para a estimação de sexo, idade e maior/menor de 14 e 18 anos utilizando as razões fotoantropométricas faciais (RFA), seguindo a metodologia apresentada no Capítulo 3. Vale ressaltar que todos os testes a seguir foram realizados utilizando a base de dados apresentada na Subseção 3.3.1 e de maneira similar exposta na seção anterior, os testes a seguir apresentam os resultados da metodologia desenvolvida para estimação automática de sexo e idade usando a arquitetura da rede neural artificial proposta e detalhada na Subseção 3.3.3, incluindo todos os valores de acurácia obtidos a partir dos resultados detalhados e das matrizes de confusão para cada teste proposto.

Para avaliar o teste de significância estatística das RFAs foi realizado um estudo estatístico descritivo do conjunto de dados proposto, que serve como entrada para o modelo de aprendizagem de máquinas proposto. Como descrito na Subseção 3.3.1, o conjunto completo de dados contém 500 observações sobre 208 variáveis para cada categoria de Idade (18 níveis) e Sexo (2 níveis), produzindo 18.000 observações no total. Dado o grande número de variáveis e categorias, não é uma opção viável descrever todas as distribuições de variáveis em todas as categorias. Portanto, foi realizada uma análise visual e detalhada dos *boxplots* das distribuições de todas as variáveis em todas as 36 categorias. Um exemplo para a variável RFA-10 (Asa do nariz - queixo) pode ser encontrado na Figura 4.4. Os indivíduos do sexo masculino apresentam valores maiores que as do sexo feminino e as diferenças aumentam com a idade. Figuras similares para todas as 208 variáveis podem ser encontradas no Apêndice B.

Foram realizados os testes de normalidade de Shapiro-Wilk (WILK; SHAPIRO, 1965)

Distribuições da RFA_10 por Sexo e Idade

idades de 5 até 22 anos

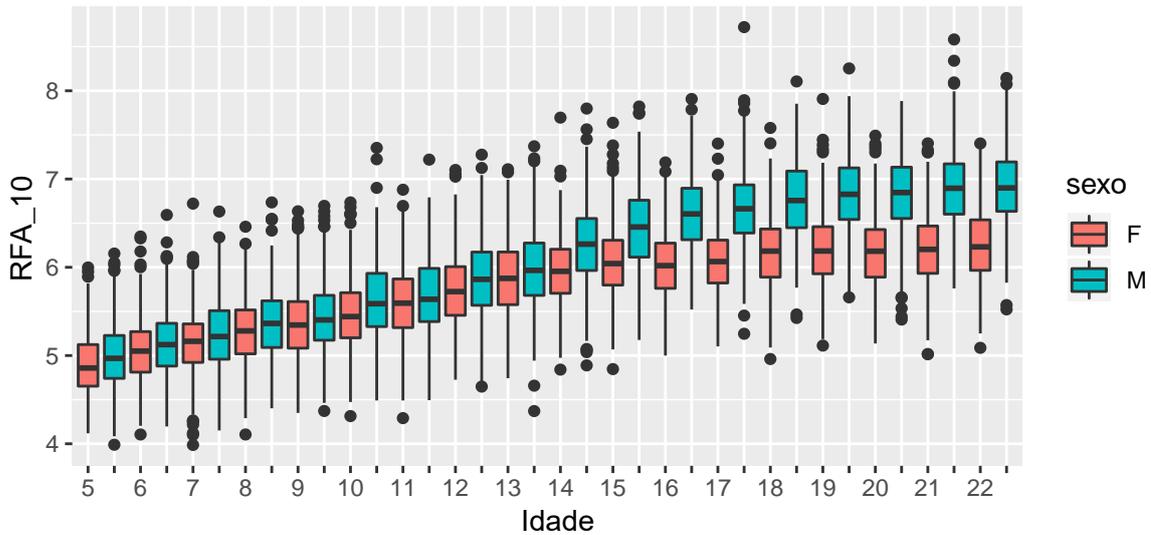


Figura 4.4: *Boxplots* da RFA-10 (asa do nariz - queixo) para cada sexo e faixa etária.

em cada grupo etário para cada variável. A hipótese nula para este teste é que os dados são normalmente distribuídos. Onde o *P values* menores que 0,01 foram considerados indicativos de desvios significativos da normalidade. Três variáveis não eram normais em todos os grupos etários: RFA-154 (diâmetro da íris), RFA-160 (íris lateral - pupila) e RFA-171 (íris medial - pupila, mesmo lado). Para as outras variáveis, aproximadamente 12% dos testes rejeitaram a normalidade (cerca de dois grupos idade-sexo por variável). No entanto, dado o grande número de observações em cada categoria e a presença de muitos *outliers* (ver Figura 4.4, por exemplo), isso sugere que grande parte dos dados é normalmente distribuída e que técnicas de análise que dependem da normalidade podem ser usadas, embora com cautela. Análises de variância bidirecional (ANOVA) (KUTNER, 2005) foram realizadas em cada RFA para avaliar mudanças estatisticamente significativas nos parâmetros faciais em resposta aos fatores sexo, idade e interação entre sexo e idade. O valor de *P values* menor que 0,01 foi considerado significativo. Para cada um das 208 RFAs, tanto o sexo quanto a idade foram fatores significativos. A interação entre sexo e idade não foi significativa para apenas 4 dos 208 RFAs, especificamente RFA-50 (comissura labial - *Zygion*, mesmo lado), RFA-154 (diâmetro da íris), RFA-160 (íris lateral - pupila) e RFA-171 (íris medial - pupila do mesmo lado). Três destas quatro variáveis foram identificadas como não-normais em todas as categorias pelos testes de Shapiro-Wilk apresentados acima, apenas o RFA-50 não foi. Como exemplo, as distribuições do RFA-160 são apresentadas na Figura 4.5. É interessante observar que a inclusão dessas variáveis no modelo de aprendizagem de máquinas proposto não apresenta dificuldades, como ocorreria em um modelo de regressão padrão onde grandes correlações e/ou a falta de variação causaria instabilidade nas estimativas do modelo. O modelo simplesmente não usa as variáveis que não fornecem poder preditivo adicional.

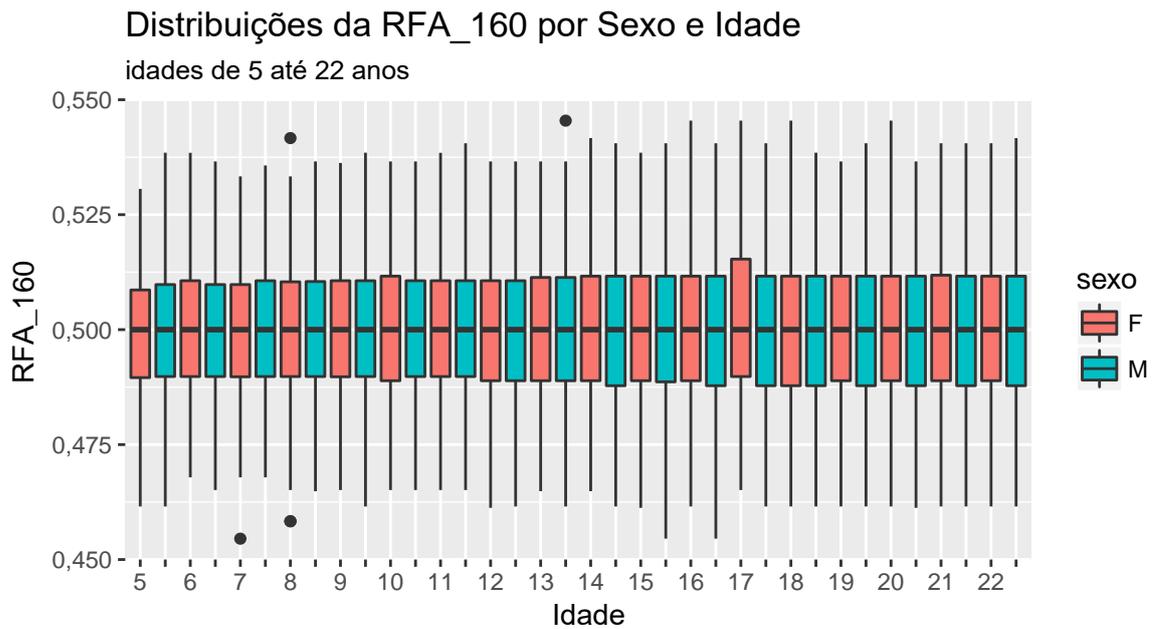


Figura 4.5: *Boxplots* da RFA-160 (lateral da íris - pupila) para cada sexo e faixa etária.

Para o **Grupo A**, os testes avaliados descrevem como as razões fotoantropométricas (RFA) podem classificar as informações sobre sexo. A Figura 4.6 apresenta os resultados para estimação do sexo dividido por idade e a última coluna (todas) foi obtida usando todas as idades no processo de classificação, para avaliar a classificação do sexo (desconsiderando a informação da idade) definida como teste de base ou como teste “global”. Como resultado é possível comparar a média dos resultados de cada idade com o teste “global”, o resultado é similar: 83% e 81%, respectivamente.

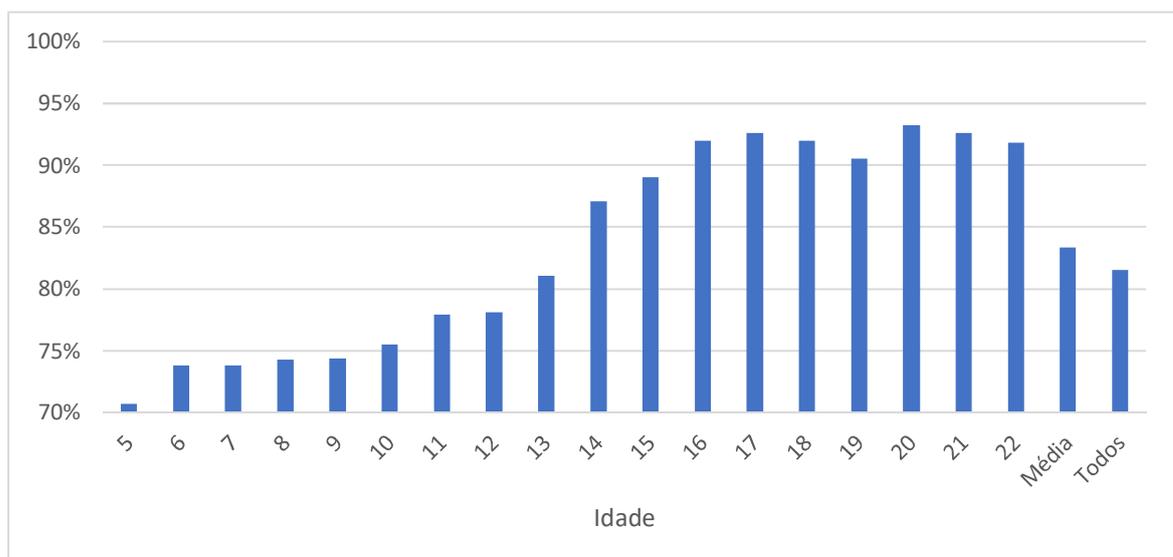


Figura 4.6: Grupo A: Resultados para estimação de sexo separados por idade, resultado da média das idades e por último, um teste utilizando todas as idades da base de dados.

Os testes do **Grupo B** foram definidos para utilizar as informações dos índices RFA para

classificação de idade. A Figura 4.7 apresenta os resultados MAE para estimativa de idade dividida em quatro grupos: intervalos de 1 ano (verde), intervalos de 2 anos (azul), intervalos de 4 anos (vermelho) e intervalos de 5 anos (roxo). Cada teste de grupo foi dividido em três etapas: o primeiro é a estimativa de idade em indivíduos do sexo masculino. O segundo apenas indivíduos femininos e o último usando os dois desconsiderando a informação do sexo no processo de classificação automática.

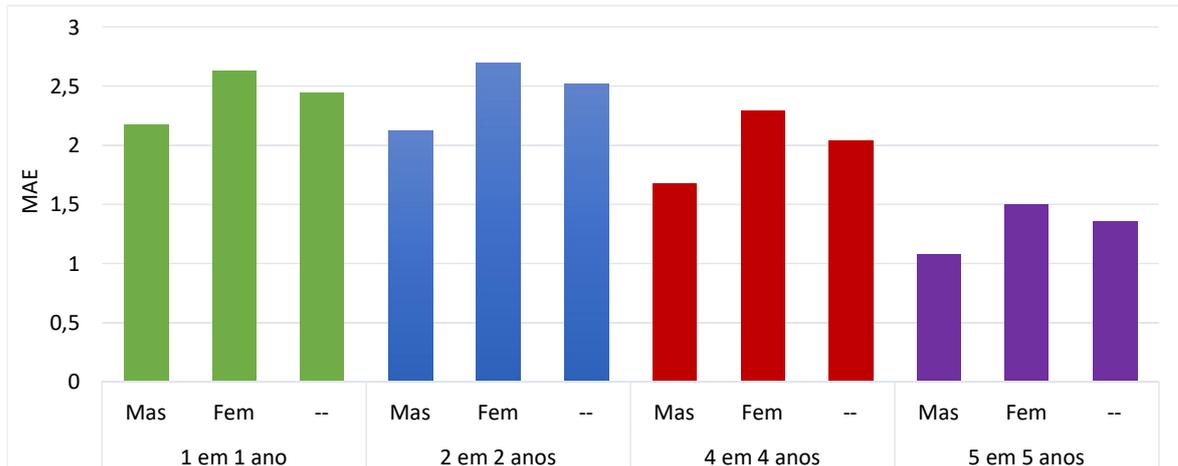


Figura 4.7: Grupo B: Resultado do erro absoluto médio (MAE) para estimação de idade para os quatro cenários teste separados por masculino, feminino e sem o uso da informação de sexo.

O teste do **Grupo C** é focado em avaliar se as RFAs podem classificar corretamente as informações da faixa etária. A Figura 4.8 apresenta o F_1 score para estimativa do grupo etário dividido em dois testes: menores/maiores de 14 anos e menores/maiores de 18 anos. Para cada grupo, o teste foi dividido em três etapas exatamente como no teste do **Grupo B**, o primeiro em indivíduos do sexo masculino, indivíduos do sexo feminino e o último desconsiderando a informação do sexo.

Para cada teste em grupo, neste caso **Grupo A**, **Grupo B** e **Grupo C**, foi abordada a métrica de matriz de confusão para apresentar detalhadamente os resultados obtidos para classificação de idade e sexo. Neste caso, mostrando a precisão dos classificadores para cada classe de saída que pré-configuram os “classes estimadas” quando comparados com as informações dos “classes verdadeiras”.

A Figura 4.9 apresenta as matrizes de confusão para os testes do **Grupo A**. As imagens da Figura 4.9 (a) até a Figura 4.9 (r) apresentam as matrizes de confusão para cada faixa etária separadamente, de 5 a 22 anos, respectivamente. A Figura 4.9 (s) apresenta os resultados médios de todas as faixas etárias, enquanto a Figura 4.9 (t) apresenta os resultados utilizando todos os dados desconsiderando as informações de idade.

As Figuras 4.10, 4.11 e 4.12 apresentam as matrizes de confusão com resultados detalhados para os testes no **Grupo B**, utilizando 1 ano para intervalos de idade. A Figura 4.10 apresenta os resultados detalhados para estimativa de idade, desconsiderando a informação

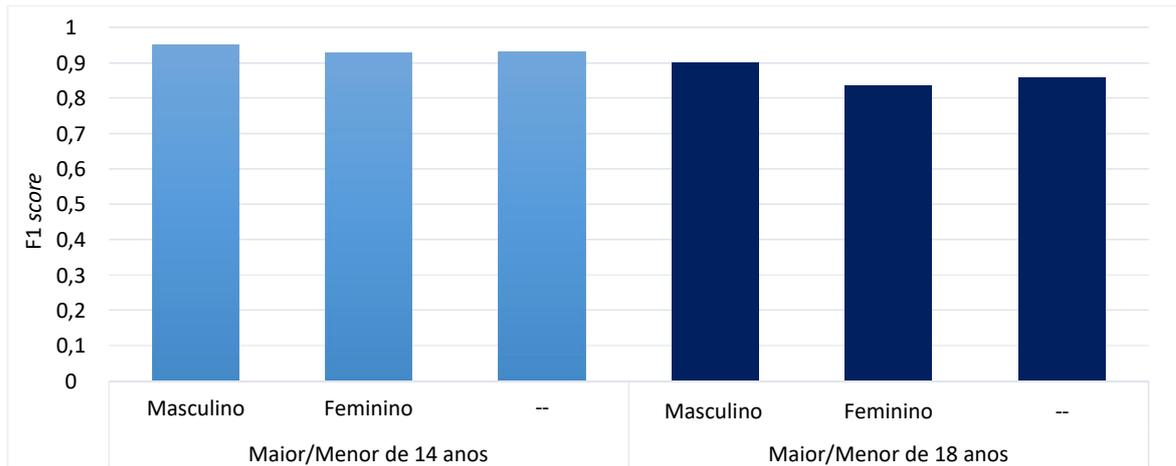


Figura 4.8: Grupo C: Gráfico com os resultados de F_1 score para estimativa de grupos de idade em dois cenários: limiar de 14 e 18 anos de idade. Em ambos cenários são compostos por três etapas: por sexo masculino, feminino e ambos juntos, neste último caso desconsiderando a informação de sexo no classificador.

sobre sexo. A Figura 4.11 apresenta os resultados detalhados para estimativa de idade em indivíduos do sexo feminino. A Figura 4.12 apresenta os resultados detalhados para estimativa de idade em indivíduos do sexo masculino.

As Figuras 4.13, 4.14 e 4.15 apresentam as matrizes de confusão com os resultados detalhados do **Grupo B**: intervalos de idade de 2 anos. A Figura 4.13 apresenta os resultados detalhados para estimativa de idade, desconsiderando a informação sobre sexo. A Figura 4.14 e a Figura 4.15 apresentam os resultados detalhados para estimativa de idade para indivíduos do sexo feminino e masculino, respectivamente.

A Figura 4.16 apresenta as matrizes de confusão com os resultados detalhados do **Grupo B**: com intervalos de idade de 4 anos. A Figura 4.16 (a) apresenta os resultados detalhados para estimativa de idade, desconsiderando a informação sobre sexo. A Figura 4.16 (b) apresenta os resultados detalhados para estimativa de idade em indivíduos do sexo feminino. A Figura 4.16 (c) apresenta os resultados detalhados para estimativa de idade em indivíduos do sexo masculino.

A Figura 4.17 apresenta as matrizes de confusão com os resultados detalhados do **Grupo B**: com intervalos de idade de 5 anos. A Figura 4.17 (a) apresenta os resultados detalhados para estimativa de idade, desconsiderando a informação sobre sexo. A Figura 4.17 (b) apresenta os resultados detalhados para estimativa de idade em indivíduos do sexo feminino. A Figura 4.17 (c) apresenta os resultados detalhados para estimativa de idade em indivíduos do sexo masculino.

A Figura 4.18 apresenta as matrizes de confusão com os resultados detalhados do **Grupo C**: menores/maiores de 14 anos. A Figura 4.18 (a) apresenta os resultados detalhados para estimativa de grupo etário desconsiderando a informação sobre sexo. A Figura 4.18 (b) apresenta os resultados detalhados para estimativa de grupos etários em indivíduos do sexo

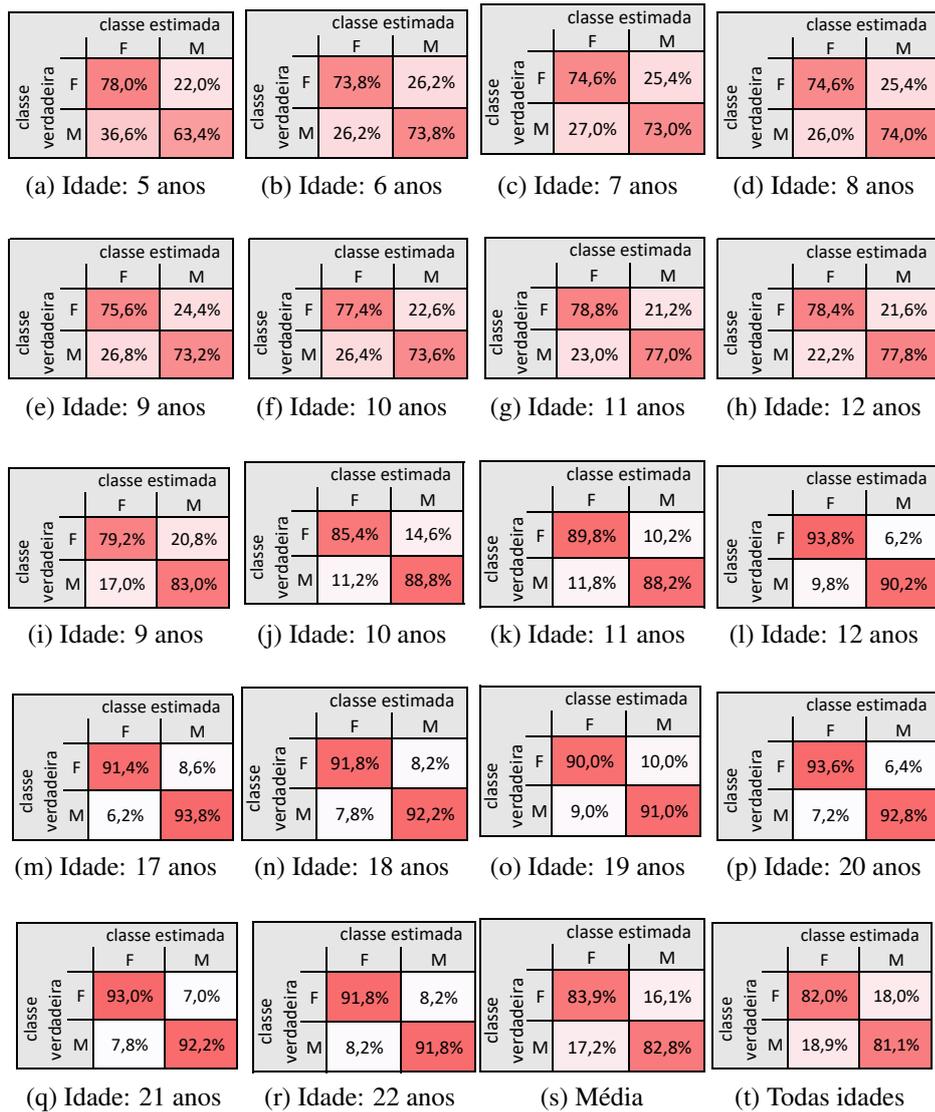


Figura 4.9: Matrizes de confusão para estimação de sexo para cada idade (a) até (r), média entre as idades (s) e o teste que engloba todas as idades (t).

		classe estimada																
		6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22
classe verdadeira	6	58,00%	23,90%	6,50%	5,90%	2,10%	2,20%	0,90%	0,10%	0,10%	0,10%	0,00%	0,10%	0,00%	0,00%	0,00%	0,00%	0,10%
	7	42,50%	27,30%	9,50%	10,50%	4,00%	3,50%	1,80%	0,50%	0,10%	0,10%	0,00%	0,00%	0,00%	0,00%	0,00%	0,10%	0,00%
	8	24,40%	21,50%	12,90%	16,50%	8,90%	9,30%	3,30%	1,30%	0,40%	0,30%	0,40%	0,20%	0,20%	0,20%	0,00%	0,10%	0,10%
	9	14,70%	15,80%	11,50%	20,00%	10,80%	12,20%	5,60%	3,90%	1,50%	0,50%	0,80%	0,60%	0,80%	0,20%	0,30%	0,10%	0,70%
	10	8,10%	7,80%	9,20%	16,10%	13,20%	15,90%	12,00%	5,90%	4,60%	1,30%	2,20%	0,60%	0,50%	0,80%	1,10%	0,10%	0,60%
	11	3,70%	5,80%	6,00%	14,00%	13,30%	17,50%	11,90%	9,40%	4,70%	3,50%	2,80%	1,90%	1,10%	0,80%	0,80%	1,40%	1,40%
	12	1,70%	3,00%	3,10%	7,60%	9,40%	17,30%	14,20%	13,00%	7,70%	5,10%	3,70%	3,00%	2,20%	2,60%	2,00%	2,30%	2,10%
	13	1,20%	1,30%	1,90%	3,80%	5,40%	12,80%	13,70%	12,00%	13,90%	6,80%	7,60%	4,30%	4,40%	2,60%	3,20%	1,30%	3,80%
	14	0,20%	0,30%	0,90%	1,50%	3,10%	7,20%	9,40%	11,90%	13,60%	11,00%	10,50%	6,70%	5,50%	4,50%	4,40%	3,70%	5,60%
	15	0,20%	0,20%	0,30%	1,20%	1,80%	5,60%	7,20%	8,30%	10,30%	9,90%	11,50%	8,30%	8,30%	6,30%	5,00%	6,80%	8,80%
	16	0,10%	0,20%	0,10%	0,80%	1,60%	3,20%	5,40%	7,40%	8,90%	8,80%	10,50%	7,70%	9,80%	7,30%	9,30%	6,90%	12,00%
	17	0,00%	0,00%	0,10%	1,00%	1,60%	3,30%	4,30%	6,00%	8,40%	7,90%	10,80%	9,70%	9,50%	7,40%	8,00%	8,80%	13,20%
	18	0,00%	0,00%	0,10%	1,10%	1,40%	1,20%	4,30%	4,50%	6,60%	7,30%	9,20%	8,20%	10,00%	10,80%	8,30%	9,80%	17,20%
	19	0,00%	0,00%	0,20%	0,70%	1,00%	1,40%	2,90%	3,80%	5,50%	5,70%	7,90%	8,00%	9,90%	10,70%	10,90%	12,10%	19,30%
	20	0,00%	0,10%	0,00%	1,30%	0,60%	1,80%	2,00%	3,60%	5,30%	6,50%	7,80%	7,60%	8,90%	11,80%	11,60%	13,60%	17,50%
	21	0,00%	0,00%	0,00%	0,50%	0,50%	1,30%	3,20%	2,80%	4,70%	5,50%	7,60%	6,60%	10,10%	10,70%	10,30%	14,80%	21,40%
	22	0,10%	0,00%	0,10%	0,20%	1,00%	1,50%	1,60%	2,20%	5,70%	3,70%	8,00%	8,00%	10,00%	10,60%	9,00%	14,90%	23,40%

Figura 4.10: Matriz de confusão: estimação de idade com intervalo de 1 em 1 ano.

		classe estimada																
		6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22
classe verdadeira	6	50,80%	24,60%	13,80%	5,20%	3,20%	0,80%	0,60%	0,40%	0,20%	0,00%	0,20%	0,20%	0,00%	0,00%	0,00%	0,00%	0,00%
	7	32,40%	28,00%	19,20%	8,80%	6,00%	2,40%	1,60%	0,40%	0,40%	0,20%	0,20%	0,20%	0,20%	0,00%	0,00%	0,00%	0,00%
	8	19,00%	21,40%	21,20%	14,00%	12,00%	6,80%	2,40%	1,40%	0,40%	0,40%	0,00%	0,00%	0,20%	0,40%	0,20%	0,00%	0,20%
	9	10,00%	13,80%	19,80%	12,60%	17,00%	9,20%	5,00%	2,80%	2,20%	1,80%	1,40%	0,60%	1,40%	0,40%	0,60%	1,00%	0,40%
	10	4,20%	6,40%	14,80%	14,60%	17,20%	13,00%	8,60%	5,00%	3,60%	2,60%	2,80%	1,80%	1,80%	1,20%	1,00%	0,20%	1,20%
	11	2,00%	4,40%	5,80%	11,60%	13,40%	14,00%	12,80%	11,40%	5,40%	3,20%	4,00%	2,80%	2,40%	0,80%	1,00%	2,60%	2,40%
	12	0,80%	2,20%	4,80%	5,00%	9,60%	14,60%	11,00%	12,20%	7,60%	8,60%	4,20%	6,20%	3,60%	3,00%	1,60%	2,20%	2,80%
	13	0,00%	0,80%	2,60%	2,00%	8,00%	10,20%	10,80%	11,60%	9,40%	9,80%	4,80%	8,20%	6,00%	4,20%	3,00%	3,80%	4,80%
	14	0,00%	0,20%	0,60%	2,20%	4,60%	4,60%	8,00%	11,00%	10,40%	11,20%	8,80%	9,20%	6,80%	7,40%	3,80%	5,80%	5,40%
	15	0,20%	0,00%	0,40%	1,00%	3,40%	4,60%	6,60%	8,80%	12,00%	8,60%	5,20%	9,00%	11,60%	7,40%	6,00%	9,40%	5,80%
	16	0,20%	0,20%	0,80%	1,00%	2,60%	4,40%	5,40%	6,80%	11,80%	8,20%	5,40%	10,20%	7,80%	10,20%	7,40%	9,80%	7,80%
	17	0,20%	0,00%	0,40%	1,00%	2,40%	3,20%	4,40%	7,40%	10,00%	9,60%	7,60%	8,20%	10,20%	9,00%	7,20%	11,80%	7,40%
	18	0,00%	0,20%	0,40%	1,80%	1,60%	3,20%	3,80%	4,60%	8,20%	11,20%	3,60%	5,20%	10,00%	13,00%	7,80%	12,60%	12,80%
	19	0,00%	0,00%	0,20%	0,60%	1,60%	1,80%	2,00%	5,00%	7,80%	9,20%	5,80%	6,60%	14,00%	10,20%	9,40%	11,60%	14,20%
	20	0,00%	0,20%	0,20%	1,00%	1,80%	2,40%	2,00%	4,20%	6,20%	9,40%	5,00%	8,20%	10,00%	10,80%	10,20%	14,80%	13,60%
	21	0,00%	0,00%	0,20%	0,60%	1,60%	1,60%	1,00%	3,40%	6,00%	7,40%	6,20%	6,20%	12,00%	10,40%	9,20%	17,80%	16,40%
	22	0,00%	0,00%	0,60%	0,80%	0,80%	1,40%	2,60%	3,20%	6,60%	7,60%	4,60%	7,80%	12,00%	10,80%	9,80%	18,80%	12,60%

Figura 4.11: Matriz de confusão: estimação de idade com intervalo de 1 em 1 ano para sexo feminino.

		classe estimada																
		6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22
classe verdadeira	6	49,00%	20,40%	13,40%	9,60%	4,20%	1,80%	1,20%	0,20%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,20%
	7	35,60%	23,40%	14,40%	12,40%	8,00%	2,40%	2,20%	1,20%	0,40%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%
	8	24,00%	17,60%	16,40%	15,40%	9,40%	8,80%	4,40%	2,60%	0,80%	0,60%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%
	9	13,00%	12,00%	17,80%	18,40%	13,00%	10,80%	8,20%	4,40%	0,80%	0,80%	0,40%	0,40%	0,00%	0,00%	0,00%	0,00%	0,00%
	10	6,20%	6,20%	11,20%	11,20%	21,80%	15,40%	12,00%	8,80%	2,60%	1,40%	0,60%	0,80%	0,00%	0,60%	0,40%	0,60%	0,20%
	11	4,60%	4,00%	10,40%	12,80%	18,20%	12,80%	11,60%	12,40%	5,40%	3,20%	0,60%	1,00%	0,40%	0,80%	0,80%	0,80%	0,20%
	12	1,60%	1,60%	5,40%	8,20%	15,20%	10,20%	15,20%	18,60%	9,00%	4,60%	2,40%	1,60%	1,80%	2,00%	1,00%	0,40%	1,20%
	13	0,80%	0,80%	3,60%	5,20%	8,40%	9,00%	12,80%	17,40%	12,40%	8,00%	7,20%	5,00%	3,00%	1,60%	1,80%	1,40%	1,60%
	14	0,40%	0,20%	0,20%	2,00%	3,60%	5,80%	9,20%	12,60%	13,20%	12,40%	8,60%	11,00%	6,40%	4,00%	5,20%	3,20%	2,00%
	15	0,40%	0,00%	0,20%	0,40%	1,80%	2,00%	6,80%	10,00%	11,80%	10,40%	11,20%	9,80%	9,20%	5,60%	7,60%	7,80%	5,00%
	16	0,00%	0,00%	0,00%	0,00%	1,40%	1,60%	2,80%	6,80%	6,60%	10,20%	13,80%	12,00%	10,40%	9,00%	10,60%	8,60%	6,20%
	17	0,00%	0,00%	0,00%	0,40%	0,60%	1,00%	3,20%	3,20%	4,80%	10,80%	12,60%	12,80%	11,20%	10,80%	9,20%	10,00%	9,40%
	18	0,00%	0,00%	0,20%	0,20%	0,20%	0,40%	1,60%	2,40%	7,20%	7,20%	8,40%	10,80%	12,20%	13,00%	12,40%	12,60%	11,20%
	19	0,00%	0,00%	0,00%	0,00%	0,20%	0,60%	1,80%	2,80%	1,60%	6,40%	10,40%	12,80%	10,40%	11,80%	13,60%	13,00%	14,60%
	20	0,00%	0,00%	0,20%	0,00%	0,20%	0,60%	0,20%	2,40%	2,80%	6,40%	11,60%	10,40%	9,00%	12,60%	13,80%	12,40%	17,40%
	21	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,80%	1,80%	4,40%	6,40%	6,20%	10,60%	9,80%	12,80%	12,60%	17,00%	17,60%
	22	0,00%	0,00%	0,00%	0,00%	0,40%	0,20%	0,40%	2,20%	2,40%	3,80%	6,80%	8,60%	12,40%	13,80%	15,00%	15,40%	18,60%

Figura 4.12: Matriz de confusão: estimação de idade com intervalo de 1 em 1 ano para sexo masculino.

		classe estimada								
		6	8	10	12	14	16	18	20	22
classe verdadeira	6	73,20%	17,10%	7,30%	2,00%	0,40%	0,00%	0,00%	0,00%	0,00%
	8	33,80%	30,40%	24,30%	7,20%	2,40%	1,00%	0,10%	0,40%	0,40%
	10	8,90%	20,60%	32,80%	20,30%	8,30%	3,10%	1,90%	2,60%	1,50%
	12	3,20%	8,90%	20,50%	26,40%	19,40%	7,60%	4,50%	4,60%	4,90%
	14	0,30%	1,70%	7,00%	15,60%	28,70%	14,80%	9,90%	10,00%	12,00%
	16	0,10%	1,00%	4,10%	9,30%	21,30%	15,60%	13,70%	14,20%	20,70%
	18	0,10%	0,80%	2,60%	5,40%	14,40%	14,40%	18,90%	16,20%	27,20%
	20	0,00%	0,50%	2,30%	4,10%	13,20%	15,10%	14,40%	20,50%	29,90%
	22	0,30%	0,40%	1,20%	2,90%	11,10%	11,40%	13,30%	20,40%	39,00%

Figura 4.13: Matriz de confusão: estimação de idade com intervalo de 2 em 2 anos.

		classe estimada								
		6	8	10	12	14	16	18	20	22
classe verdadeira	6	69,80%	20,20%	8,40%	0,80%	0,40%	0,40%	0,00%	0,00%	0,00%
	8	29,40%	38,40%	24,00%	4,80%	2,00%	0,40%	0,00%	0,40%	0,60%
	10	9,60%	21,80%	32,40%	15,80%	5,60%	5,40%	2,80%	4,00%	2,60%
	12	1,40%	7,80%	19,60%	23,40%	15,20%	11,60%	9,00%	7,20%	4,80%
	14	0,20%	1,40%	9,20%	15,20%	24,80%	12,20%	13,60%	14,40%	9,00%
	16	0,60%	0,80%	7,20%	10,80%	15,80%	16,80%	15,40%	15,40%	17,20%
	18	0,40%	1,20%	4,60%	6,20%	14,40%	15,20%	17,40%	19,60%	21,00%
	20	0,00%	0,20%	3,40%	5,40%	13,40%	14,20%	18,60%	22,20%	22,60%
	22	0,20%	0,80%	1,80%	4,40%	10,20%	15,40%	16,00%	23,80%	27,40%

Figura 4.14: Matriz de confusão: estimação de idade com intervalo de 2 anos para sexo feminino.

		classe estimada								
		6	8	10	12	14	16	18	20	22
classe verdadeira	6	69,40%	22,60%	5,20%	2,40%	0,20%	0,20%	0,00%	0,00%	0,00%
	8	30,40%	42,40%	14,60%	10,00%	1,80%	0,40%	0,00%	0,40%	0,00%
	10	9,00%	25,40%	31,20%	24,80%	7,80%	1,00%	0,20%	0,40%	0,20%
	12	2,20%	11,80%	20,40%	37,60%	15,80%	4,00%	3,20%	3,40%	1,60%
	14	0,20%	1,00%	8,60%	20,60%	27,80%	15,00%	9,20%	11,80%	5,80%
	16	0,00%	0,20%	1,80%	6,00%	18,20%	20,00%	16,80%	21,60%	15,40%
	18	0,00%	0,00%	1,00%	3,40%	12,40%	17,00%	20,80%	22,80%	22,60%
	20	0,00%	0,20%	1,20%	2,80%	9,60%	14,60%	19,40%	28,40%	23,80%
	22	0,00%	0,00%	0,40%	1,00%	6,60%	11,60%	16,00%	24,40%	40,00%

Figura 4.15: Matriz de confusão: estimação de idade com intervalo de 2 anos para sexo masculino.

		classe estimada				
		6	10	14	18	22
classe verdadeira	6	87,20%	12,40%	0,30%	0,00%	0,10%
	10	14,90%	65,90%	14,50%	2,80%	1,90%
	14	0,30%	14,90%	49,80%	17,10%	17,90%
	18	0,10%	4,80%	22,50%	29,80%	42,80%
	22	0,10%	3,00%	13,50%	20,50%	62,90%

(a) Sem informação de sexo.

		classe estimada				
		6	10	14	18	22
classe verdadeira	6	86,20%	12,80%	1,00%	0,00%	0,00%
	10	14,80%	63,80%	12,60%	4,60%	4,20%
	14	0,80%	14,40%	44,20%	22,40%	18,20%
	18	0,40%	7,00%	19,80%	35,60%	37,20%
	22	0,20%	5,00%	15,80%	28,20%	50,80%

(b) Sexo feminino.

		classe estimada				
		6	10	14	18	22
classe verdadeira	6	89,00%	10,80%	0,00%	0,20%	0,00%
	10	14,40%	74,00%	9,40%	1,20%	1,00%
	14	0,60%	15,00%	57,00%	16,80%	10,60%
	18	0,00%	1,80%	16,80%	45,80%	35,60%
	22	0,00%	1,00%	12,60%	30,80%	55,60%

(c) Sexo masculino.

Figura 4.16: Matriz de confusão: estimação de idade com intervalo de 4 anos.

		classe estimada			
		5	10	15	20
classe verdadeira	5	94,70%	5,30%	0,00%	0,00%
	10	8,80%	78,70%	9,90%	2,60%
	15	0,00%	12,50%	57,30%	30,20%
	20	0,10%	4,70%	26,90%	68,30%

(a) Sem informação de sexo.

		classe estimada			
		5	10	15	20
classe verdadeira	5	92,20%	7,80%	0,00%	0,00%
	10	6,60%	78,00%	10,80%	4,60%
	15	0,00%	13,40%	56,20%	30,40%
	20	0,00%	6,40%	29,00%	64,60%

(b) Sexo feminino.

		classe estimada			
		5	10	15	20
classe verdadeira	5	92,00%	8,00%	0,00%	0,00%
	10	6,40%	84,40%	8,20%	1,00%
	15	0,00%	10,20%	65,20%	24,60%
	20	0,00%	1,40%	23,80%	74,80%

(c) Sexo masculino.

Figura 4.17: Matriz de confusão: estimação de idade com intervalo de 5 anos.

feminino. A Figura 4.18 (c) apresenta os resultados detalhados para estimativa de grupos etários em indivíduos do sexo masculino.

		classe estimada	
		≥ 14	< 14
classe verdadeira	≥ 14	94,90%	5,10%
	< 14	9,65%	90,35%

(a) Sem informação de sexo.

		classe estimada	
		≥ 14	< 14
classe verdadeira	≥ 14	95,27%	4,73%
	< 14	10,70%	89,30%

(b) Sexo feminino.

		classe estimada	
		≥ 14	< 14
classe verdadeira	≥ 14	95,33%	4,67%
	< 14	5,20%	94,80%

(c) Sexo masculino.

Figura 4.18: Estimação grupo de idade: limiar de 14 anos.

A Figura 4.19 apresenta as matrizes de confusão com os resultados detalhados do Grupo C: menores/maiores de 18 anos. A Figura 4.19 (a) apresenta os resultados detalhados para estimativa de grupo etário desconsiderando a informação sobre sexo. A Figura 4.19 (b) apresenta os resultados detalhados para estimativa de grupos etários em indivíduos do sexo feminino. A Figura 4.19 (c) apresenta os resultados detalhados para estimativa de grupos etários em indivíduos do sexo masculino.

4.3 ESTIMAÇÃO AUTOMÁTICA DE IDADE E SEXO USANDO IMAGENS FACIAIS E RAZÕES FOTOANTROPOMÉTRICAS

Nesta seção são apresentados os testes e análises realizados no protótipo estimação de informações antropométricas utilizando as imagens faciais (**IMG**) e também a combinação

		classe estimada	
		>= 18	< 18
classe verdadeira	>= 18	85,40%	14,60%
	< 18	13,70%	86,30%

(a) Sem informação de sexo.

		classe estimada	
		>= 18	< 18
classe verdadeira	>= 18	83,10%	16,90%
	< 18	16,20%	83,80%

(b) Sexo feminino

		classe estimada	
		>= 18	< 18
classe verdadeira	>= 18	89,50%	10,50%
	< 18	9,33%	90,67%

(c) Sexo masculino.

Figura 4.19: Estimação grupo de idade: limiar de 18 anos.

destas com as razões fotoantropométricas faciais (**IMG+RFA**), seguindo a estrutura de avaliação descrita na seção anterior apresentada em três grupos distintos. Com os resultados disponíveis, e com o intuito de comparar os resultados, estes são expostos a seguir juntamente com os valores apresentados anteriormente (**RFA**). Vale ressaltar que como descrito no capítulo anterior, os testes **IMG** e **IMG+RFA** além de utilizar mais idades (de 2 até 4 anos) também utilizaram de uma base com uma quantidade significativamente maior quando comparado com os testes realizados apenas com as razões fotoantropométricas (**RFA**), sendo 105 mil amostras contra 18 mil respectivamente.

Outros trabalhos para estimação automática de idade com imagens faciais utilizando redes neurais profundas não apresentam testes com diferentes variações de idades (2 em 2, 4 em 4 e ou 5 em 5 anos) como nos resultados anteriores (**RFA**). Para os modelos **IMG** e **IMG+RFA** o procedimento relacionado ao **Grupo A** foi definido e executado apenas para o teste mais restrito, sendo este com a variação de idade de 1 em 1 ano, onde este nos testes da seção anterior resultou o pior resultado MAE para a estimação de idade utilizando as RFAs. Os demais testes como estimação de sexo (**Grupo B**) e estimação de menor e maior para 14 e 18 anos (**Grupo C**) foram executados de maneira igual.

Para os testes relacionados ao **Grupo A**, a Figura 4.20 apresenta os resultados comparando as três abordagens (**RFA**, **IMG** e **IMG+RFA**) para estimação de sexo para cada faixa etária específica, onde para os testes realizados utilizando as RFAs esta começa a partir de 5 anos de idade enquanto os testes com imagens e imagens com RFAs começam a partir de 2 anos. A Figura 4.21 apresenta o resultado geral dos três modelos em questão, neste caso os modelos foram gerados para estimar o sexo independente da idade. Por último a Figura 4.22 apresenta os resultados MAE para estimação de idade dos três modelos descritos neste trabalho, lembrando que esses resultados são para estimação de idade com variação de idade de 1 em 1 ano e também sem considerar a informação de sexo dos indivíduos, a Figura 4.23 apresenta a média de idade resultante para cada classe no processo de estimação de idade, nesta é possível visualizar uma dificuldade para estimação de idade em indivíduos acima de 18 anos. Por fim os resultados do Grupo C, a Tabela 4.4 apresenta os resultados detalhados de F_1 score para os limiares de 14 e 18 anos de idade separados por sexo masculino, feminino e sem sexo para os modelos utilizando as RFAs, o utilizando apenas imagens e por último, o modelo combinado de imagens com as RFAs.

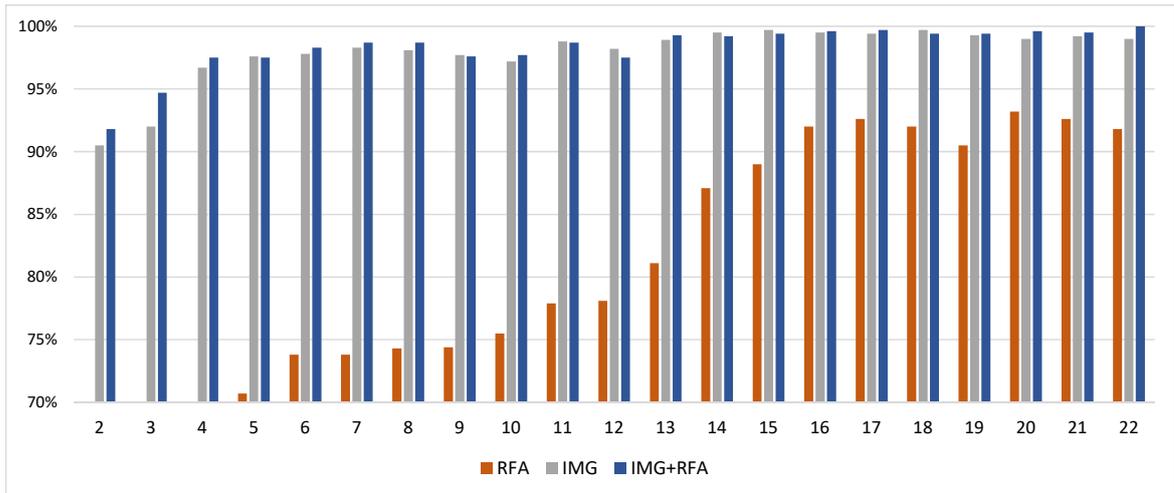


Figura 4.20: Grupo A: Gráfico dos resultados para estimação de sexo separados por idade e por modelo, sendo eles: utilizando RFAs, utilizando imagens e por último utilizando imagens combinadas com as RFAs.

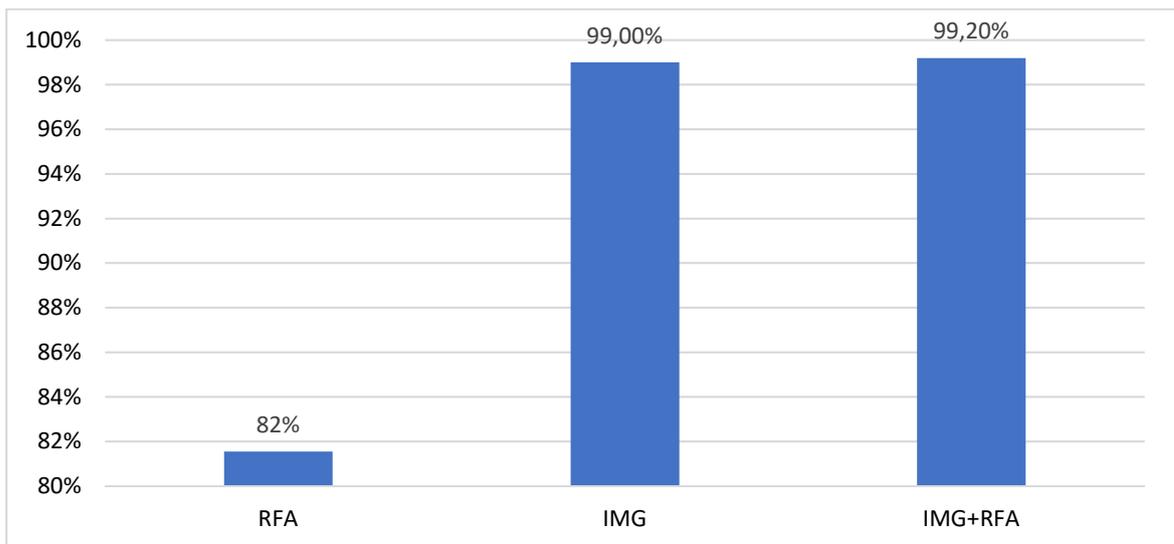


Figura 4.21: Grupo A: Gráfico dos resultados para estimação de sexo geral para cada modelo, sendo eles: utilizando RFAs, utilizando imagens e por último utilizando imagens combinadas com as RFAs.

Tabela 4.4: Grupo C: Resultados de F_1 score para testes de limiar de idade para menores e maiores de 14 e 18 anos separado por sexo e pelos modelos usando as RFAs, imagens e imagens combinadas com as RFAs.

	MAIOR/MENOR DE 14 ANOS			MAIOR/MENOR DE 18 ANOS		
	Mas	Fem	-	Mas	Fem	-
RFA	0,9512	0,9288	0,9308	0,902	0,8352	0,8594
IMG	0,9532	0,9444	0,9531	0,9354	0,9062	0,9259
IMG+RFA	0,9593	0,9552	0,957	0,9423	0,9147	0,9266

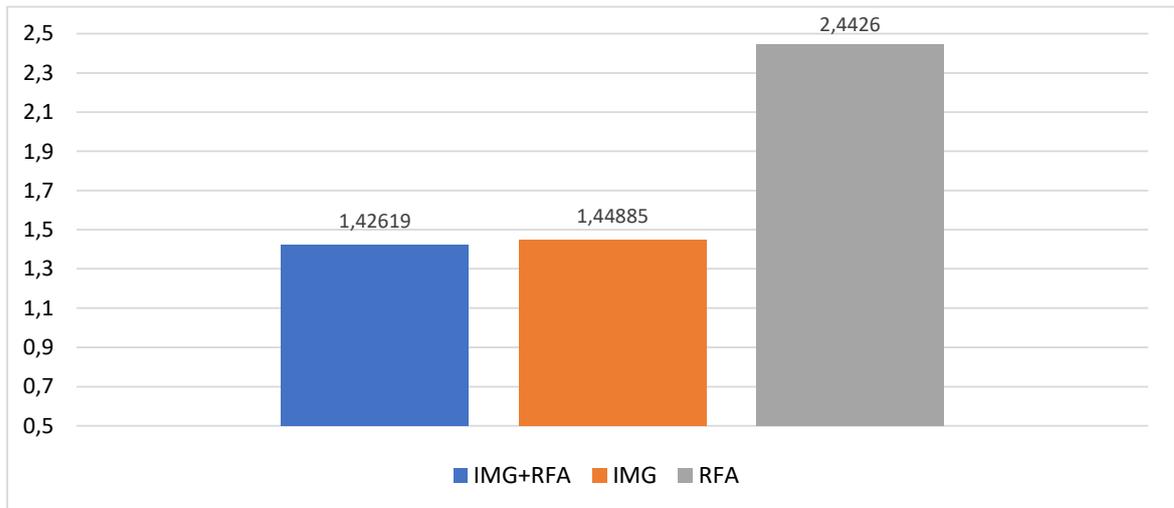


Figura 4.22: Grupo B: Gráfico dos resultados MAE para estimação de sexo separados por idade, resultado da média das idades e por último, um teste utilizando todas as idades da base de dados.

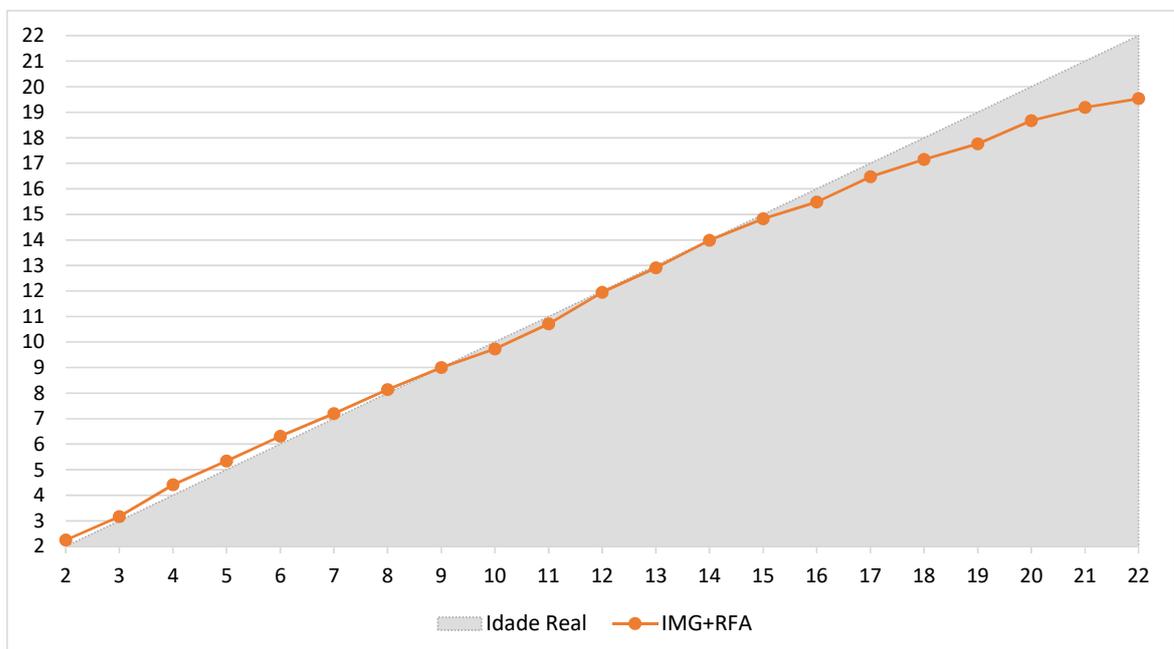


Figura 4.23: Grupo B: Gráfico dos resultados para estimação de sexo separados por idade, resultado da média das idades e por último, um teste utilizando todas as idades da base de dados.

No próximo capítulo são apresentadas as discussões sobre estimação automática de idade, sexo, limiar de idade e as conclusões do presente trabalho.

5 DISCUSSÕES

Neste trabalho foram apresentadas metodologias para estimação de idade e sexo usando imagens faciais. A primeira permitiu a identificação automática de pontos cefalométricos em imagens faciais de norma frontal. Com a identificação automática destes pontos faciais foi possível desenvolver uma abordagem para estimação automática utilizando as razões fotoantropométricas aplicando-as em redes neurais artificiais (ANN). Por fim a abordagem anterior foi combinada com uma rede neural convolucional (CNN) para estimação de idade e sexo. A seguir é apresentada uma discussão dos resultados apresentados no capítulo anterior.

5.1 IDENTIFICAÇÃO AUTOMÁTICA DOS PONTOS CEFALOMÉTRICOS

Neste trabalho foi apresentada uma abordagem de localização automática dos pontos cefalométricos em imagens faciais. Esta pode ser aplicada em várias tarefas da antropologia forense. O uso dos pontos automáticos incluem a fotoantropometria de indivíduos vivos para identificação forense, aplicação para estimativa de sexo e idade. A metodologia dos pontos cefalométricos pode ser adaptada para a identificação dos pontos em pessoas mortas, aplicado à identificação craniofacial (reconstrução e superposição), possibilitando a identificação dos pontos em crânios de indigentes por meio de correlação com os pontos identificados em imagens faciais uma base nacional de identificação.

A metodologia proposta é baseada em aprendizagem supervisionada onde um algoritmo proposto foi treinado e testado em um conjunto de 1000 imagens faciais de norma frontal, usando 28 pontos cefalométricos como referência previamente localizados por um perito forense. Além disso, foram adaptadas outras duas abordagens da literatura para detecção automática dos pontos faciais. Por fim, todas as técnicas foram comparadas entre si, e também seu desempenho considerando a dispersão de localização por especialistas humanos como referências (12 especialistas em 20 imagens).

Os resultados mostraram que a metodologia proposta supera claramente as duas outras abordagens da literatura em diferenças estatisticamente significativas e seu desempenho está próximo da dispersão da marcação dos especialistas (0,014 vs 0,009 pixel de erro médio de distância).

Como esperado, o *Zygion*, um marco do Tipo 3 de acordo com (BOOKSTEIN, 1991), mostra uma grande dispersão. Tanto nos pontos do (*Zygion*) estimados pelo método proposto (HR) quanto no caso da análise inter-especialista (*inter observers*), neste caso uma variabilidade ligeiramente maior quando comparada com as localizações dos pontos obtidos pelos especialistas (ver Figura 4.1 e Figura 4.2). Ao contrário dos estudos existentes sobre disper-

são da marcação dos pontos pelos especialistas, descritos em (CAMPOMANES-ÁLVAREZ *et al.*, 2015; CUMMAUDO *et al.*, 2013), a dispersão da marcação de outros pontos de referência do Tipo 3 foi baixa, como no caso dos pontos *Gnathion*, *Alare*, *Gonion* e *Glabella*. Novamente, essa dispersão foi semelhante nas duas abordagens: automática (metodologia proposta) e manual (12 especialistas), o que contradiz estudos prévios em que a dispersão em *Gonion* (CAMPOMANES-ÁLVAREZ *et al.*, 2015; CUMMAUDO *et al.*, 2013) e *Gnathion* (CAMPOMANES-ÁLVAREZ *et al.*, 2015) foi alta, e mesmo no ponto *Alare* com uma dispersão intermediária em (CAMPOMANES-ÁLVAREZ *et al.*, 2015). Uma possível explicação para esse fenômeno é o fato de que o *software* para coleta manual utilizado pelos especialistas facilita a localização dos pontos cefalométricos, fornecendo na ferramenta formas geométricas na face como círculos, linhas horizontais e verticais como referência para auxílio na marcação manual dos pontos. Por outro lado o *software* possui ferramentas específicas para facilitar sua localização em imagens faciais frontais. Assim, o fato de usar o *software* para localização de pontos resulta em uma menor dispersão dos pontos cefalométricos marcados manualmente por especialistas - embora o desempenho da abordagem automática proposta neste trabalho seja semelhante.

Afinal, é possível concluir que o método automático proposto é preciso e robusto para localizar os pontos cefalométricos em imagens faciais de norma frontal. Atualmente, no Departamento de Polícia Federal do Brasil, os agentes e peritos forenses utilizam uma abordagem manual (*software* usado neste trabalho pelos especialistas) para coletar os pontos cefalométricos faciais em imagens faciais. O desenvolvimento da metodologia proposta permite alcançar avanços significativos em todas as tarefas manuais, reduzindo as falhas na análise forense, onde o erro humano poderia comprometer todo o procedimento. Mesmo não sendo utilizado para a coleta definitiva, a abordagem automática dos pontos pode ser implementada no *software* manual já existente, permitindo extrair os pontos automáticos como referência agilizando o processo de marcação. Além disso, caso seja adotada a abordagem automática, esta permitirá que eles realizem pesquisas futuras aplicando a metodologia desenvolvida em milhões de imagens faciais que possuem em sua base de dados.

5.2 ESTIMAÇÃO AUTOMÁTICA DE IDADE E SEXO

Estimar a idade das vítimas e suspeitos de crimes é um procedimento essencial na casuística forense da identificação humana (SCHMELING *et al.*, 2001, 2016; SILVA *et al.*, 2013b; MACHADO *et al.*, 2017). A estimativa da idade torna-se ainda mais importante quando os limiares de idade legal são os determinados pela justiça (DEITOS *et al.*, 2015; SANTIAGO *et al.*, 2018). Atualmente, as idades de 14 e 18 anos representam o limiar de idade legal de consentimento sexual e maior idade no sistema judicial de vários países do mundo (FRANCO *et al.*, 2013; GRAUPNER, 2000). O desenvolvimento de ferramentas científicas que permitam a investigação da idade com precisão e padrões baseados em evi-

dências deve ser continuamente incentivado para promover práticas forenses ideais. A partir da hipótese de que a análise fotoantropométrica da face humana pode distinguir indivíduos mais jovens e maiores de 14 e 18 anos. Este contexto justifica a necessidade de melhorar a estimativa da idade facial por meio de análise fotoantropométrica com o objetivo de propor e testar solução para distinguir indivíduos (masculinos e femininos) com idade inferior a 14 e 18 anos, utilizando análise fotoantropométrica da face humana.

Estudos populacionais específicos sobre o uso da fotoantropometria da face para estimativa de idade são escassos na literatura científica - especialmente naqueles com amostras grandes e padronizadas (MACHADO *et al.*, 2017; FLORES *et al.*, 2019; GONZALES; MACHADO; MICHEL-CROSATO, 2018). Neste estudo, uma grande amostra de participantes brasileiros foi coletada (n=18.000) e organizada em um conjunto de dados padronizado e detalhado disponível apenas para fins acadêmicos. A padronização da amostra foi realizada por seleção de participantes do sexo masculino (n=500) e feminino (n=500) distribuídos igualmente (n=1000) em intervalos de idade de um ano (de 5 a 22 anos). Além disso, todas as imagens digitais dos participantes foram tiradas com o mesmo equipamento e seguiram protocolos previamente relatados na literatura científica (MACHADO *et al.*, 2017) e pela Organização Internacional de Aviação Civil (ICAO 9303 (International Organization for Standardization, 2005)). No escopo da estratégia de amostragem, um ganho adicional foi obtido pela escolha de participantes brasileiros, conhecidos por sua formação multirracial (SOUZA, 2016) e diversidade fenotípica (EDMONDS, 2007). Essa característica torna os resultados do estudo novos e, eventualmente, mais reproduzíveis em outras populações.

Em relação aos resultados deste trabalho, as inferências sobre a idade foram primeiramente investigadas em associação com o sexo. Mais especificamente, a informação morfológica recuperada da face humana foi testada com base em seu desempenho para classificar os indivíduos masculinos e femininos em categorias de idade (5 à 22 anos). Um teste estatístico separado foi avaliado para cada um dos 18 grupos etários. Os resultados endossaram a literatura científica, revelando dificuldades para o dimorfismo sexual em jovens participantes (<12 anos). Em particular, a média de F_1 score nos grupos etários jovens variou entre 0,7 e 0,78. Por outro lado, para participantes de 13 a 22 anos, a média da F_1 score aumentou de 0,81 para 0,91, explicitando uma melhora evidente na classificação de homens e mulheres. De acordo com a literatura científica, a diferença entre jovens e idosos é explicada pela falta de características sexuais secundárias retratadas em imagens faciais de crianças (KLOESS *et al.*, 2017).

Recentemente, Kloess *et al.* (2017) investigou os desafios na classificação de imagens de abuso sexual infantil. Em seu estudo, as inferências sobre a idade (menores ou não) foram dadas com mais facilidade e precisão em imagens de bebês e crianças pequenas, enquanto as dificuldades aumentaram quando a idade de interesse se aproximou da adolescência. Curiosamente, o tamanho maior dos olhos em comparação com as outras características faciais e a presença de dentes (leite) e lacunas interdentais emergiram como indicadores potenciais da

juventude, enquanto o uso de maquiagem foi um fator de confusão (KLOESS *et al.*, 2017). Na metodologia proposta neste trabalho, o diâmetro da íris (razão iridiana) (MACHADO *et al.*, 2017) foi utilizado como referência fixa para o cálculo das razões morfológicas da face humana - o que permite quantificar as informações qualitativas fornecidas pelos autores anteriores. Além disso, as imagens de participantes representando expressões faciais não naturais (por exemplo, sorrindo) ou usando maquiagem foram parte dos critérios de exclusão no presente estudo. Corroborado pela literatura científica (KLOESS *et al.*, 2017), esse arranjo metodológico, promoveu uma redução do viés de classificação de idade em função do sexo. Nesse contexto, o dimorfismo sexual independente da idade foi realizado como um procedimento de controle de qualidade para eliminar a influência da idade sobre o desempenho da classificação. A média de F_1 score alcançou 0,81, indicando que a metodologia de classificação automática foi capaz de distinguir adequadamente a maioria dos homens e mulheres da amostra se eles forem combinados em um único grupo. Na prática, o uso de ferramentas de classificação de idade é recomendado (sempre que aplicável) para melhor atender às necessidades de cada caso - especialmente se o caso envolver interesses de idade entre 13 e 22 anos, como a idade de consentimento sexual (GRAUPNER, 2000) e a maioridade civil (FRANCO *et al.*, 2013).

Em uma segunda fase, o estudo apresentado desencadeou uma investigação mais aprofundada com base na idade. Essa fase foi justificada pela incerteza quanto à idade cronológica das vítimas e suspeitos de crimes que são comumente observados na rotina dos serviços forenses. A montagem metodológica nesta fase agrupou não apenas participantes em intervalos de idade de um ano, mas também em intervalos maiores de idade (por exemplo, dentro de um, dois, quatro e cinco anos). Dentro de cada grupo, o desempenho foi melhor para classificar a idade do sexo masculino. Entre os grupos, a média de F_1 score foi progressivamente maior com o aumento dos intervalos etários. Consequentemente, as melhores estimativas de idade foram encontradas no grupo com intervalo de idade de cinco anos (F_1 score médio: 0,74 combinando homens e mulheres). Claramente, este resultado mostra que o processo de classificação se torna mais difícil refinando a amostra com base na idade. Uma abordagem semelhante foi usada recentemente por Machado em (MACHADO *et al.*, 2017). O autor em (MACHADO, 2015) realizou uma análise fotoantropométrica para investigar o crescimento alométrico da face humana agrupando indivíduos em intervalos de idade de quatro anos. Apesar das evidentes contribuições para a análise das alterações faciais ao longo do tempo, a configuração metodológica proposta pelos autores foi limitada em relação ao presente estudo. As vantagens destacadas no presente conjunto incluem não apenas a estratificação da amostra em grupos de quatro diferentes intervalos de idade, mas também a coleta e quantificação maior de informações morfológicas da face humana. Enquanto os autores em (MACHADO *et al.*, 2017) mapearam o crescimento facial humano com dez medidas calculadas a partir de razões baseadas no diâmetro da íris, os resultados do presente estudo foram baseados em 208 medidas calculadas com o mesmo princípio. Na prática, a melhor configuração metodológica proposta no presente estudo induz estimativas de idade

mais confiáveis e precisas.

A terceira e última fase abordada neste estudo concentrou-se em testar o método proposto de classificação para distinguir os participantes que eram mais jovens ou mais velhos do que os limites de idade legais específicos. Essa configuração foi justificada para atender especificamente às necessidades da justiça quando se trata de responder a solicitações judiciais referentes aos 14 anos de idade - relacionadas ao consentimento sexual (ZHU; AA, 2017; CARPENTER *et al.*, 2014) e 18 - relacionadas à maioridade civil (CERICATO *et al.*, 2016; MACHADO *et al.*, 2018). Os testes que foram realizados nesta fase mostraram, novamente, melhor classificação dos indivíduos do sexo masculino, tanto em relação ao limiar de 14 como 18 anos. Quando homens e mulheres foram combinados, os F_1 score médios atingiram 0,93 e 0,854 para as idades de 14 e 18 anos, respectivamente. Resultados satisfatórios também foram observados recentemente por Borges *et al.* (2018) com uma abordagem semelhante. Os autores obtiveram estimativas de acurácia (área abaixo da curva) a partir das análises da curva *Receiver Operating Characteristic* (ROC) (DELONG; DELONG; CLARKE-PEARSON, 1988) que alcançaram 0,96 e 0,90 para as idades de 14 e 18 anos, respectivamente. As diferenças entre os estudos incluem o maior tamanho da amostra na investigação atual ($n=18.000$ neste trabalho contra 1.000 utilizados pelos autores (BORGES *et al.*, 2018)) e, novamente, o maior número de medidas da face humana ($n=208$ comparado às 40 medidas usado pelos autores (BORGES *et al.*, 2018)). Na prática forense, o desempenho das abordagens de classificação usadas neste estudo fortalece e apoia seu uso para distinguir vítimas e suspeitos de crimes com idade abaixo ou acima de 14 e 18 anos.

6 CONCLUSÕES

A metodologia desenvolvida para classificar indivíduos com base em idade e sexo, utilizando informações morfológicas obtidas a partir de análises fotoantropométricas da face humana, alcançou resultados promissores. Estimativas de idade mais precisas foram encontradas em indivíduos com idade entre 13 e 22 anos; os desempenhos para estimar a idade dos indivíduos masculinos foram melhores do que nos femininos; e as classificações baseadas no limite legal de idade de consentimento sexual e maioridade civil são viáveis e promissoras.

Mesmo com resultados promissores, estes utilizando as razões fotoantropométricas para o procedimento de estimação de idade e sexo, a nova metodologia proposta, terceira parte deste trabalho, combinando imagens por meio de uma rede neural convolucional com as razões fotoantropométricas usando uma rede neural artificial, se demonstrou promissora para o desenvolvimento de uma aplicação para cenários reais na área forense. A nova metodologia proposta apresentou um avanço significativo quando comparado com a abordagem utilizando apenas as razões fotoantropométricas (RFA). Em todos os casos, sendo eles estimação de idade, sexo e limiar de idade (maior e menor de 14 e 18 anos) esta obteve melhores resultados demonstrando que a abordagem combinando imagens faciais com as razões fotoantropométricas, criando um classificador de domínio cruzado (*cross-domain*) (EO *et al.*, 2018; WANG *et al.*, 2018; CHEN *et al.*, 2019), é uma área promissora de pesquisa. Outro ponto importante a se destacar é a base utilizada para avaliar esta nova abordagem esta dispo de uma amostra com 105.000 indivíduos variando de 2 a 22 anos de idade resultando em 2.500 amostras por classe (idade e sexo). A abordagem utilizando apenas as RFAs, esta com 18.000 amostras, obteve um valor MAE robusto (2,44) mesmo quando comparado com os trabalhos de estimação de idade existentes no estado da arte que utilizam redes neurais convolucionais. A solução proposta utilizando uma rede neural convolucional (apenas imagens) obteve um ganho significativo no valor do MAE (1,44) quando comparado com a solução antropométrica (RFA), este resultado já era previsto, lembrando que nos últimos anos, esta metodologia (CNN); é o foco principal em pesquisas para estimadores de idade e sexo usando imagens faciais. A combinação das duas abordagens apresentou melhora, mesmo que pequena, no resultado MAE quando comparado só com a abordagem com imagens, de 1,44 para 1,42 respectivamente para estimação de idade em testes com as idades variando de 1 em 1 ano. Na parte de estimação de sexo, a abordagem combinada (imagem e RFA), novamente se sobressai das outras duas, onde as acurácias são de 99,2%, 99% e 83% para metodologia combinada (imagem e RFA), abordagem usando apenas imagens e RFAs respectivamente. Entretanto, para o último grupo de testes, limiar de idades, este não obteve uma grande vantagem nos resultados de F_1 score para a metodologia utilizando as RFAs, neste caso a abordagem combinada obteve um valor F_1 score de 0,957 contra 0,930 para estimação de menor e maior de 14 anos. Já para a estimação de maior e menor de 18 anos

esses valores foram 0,926 e 0,859.

6.1 TRABALHOS FUTUROS

O presente estudo descreve uma abordagem com resultados promissores, entretanto existe uma limitação importante no método fornecido neste trabalho: foi treinado e testado em imagens faciais frontais que atendem à norma ICAO 9303 (International Organization for Standardization, 2005). Trabalhos de pesquisa futuros devem ser focados em abordar e/ou testar outras técnicas automáticas em imagens que mostrem diferentes poses e condições de aquisição. Um trabalho futuro interessante diferente seria analisar se a precisão/dispersão do método atual é suficiente para outros métodos automáticos recentes em antropologia forense, como o exame facial (MARTOS *et al.*, 2018), correspondência anatômica/morfológica crânio-facial (CAMPOMANES-ÁLVAREZ *et al.*, 2018) ou sobreposição crânio-face (VALSECCHI; DAMAS; CORDÓN, 2018).

Como descrito no início deste capítulo, com a possibilidade de gerar uma base de dados dos pontos cefalométricos de milhões de indivíduos utilizando a metodologia proposta neste trabalho, pesquisas futuras devem focar em efetuar um estudo da média para os pontos cefalométricos separando-os por sexo, idade, ancestralidade e região do país. Neste contexto é possível efetuar estudos da população e também gerar novas aplicações forenses baseadas nesta amostra, por exemplo, é possível com uma imagem de um indivíduo novo (3 anos de idade), utilizando técnicas de processamento de imagens, estimar o crescimento facial deste para uma idade específica posterior, podendo auxiliar em aplicações para identificação de crianças desaparecidas (YANG *et al.*, 2016; KOUDELOVÁ *et al.*, 2019). Além disso, com os pontos faciais já mapeados, estes permitirão outros trabalhos com foco em identificação de características em imagens. Neste caso pesquisas futuras devem focar na identificação dos pontos faciais em vídeos sendo possível utilizá-los em uma solução para ser aplicada em faces não padronizadas (NATH *et al.*, 2019; MATHIS *et al.*, 2018; INSAFUTDINOV *et al.*, 2016).

Uma última linha de pesquisa futura com os pontos cefalométricos, que é possível de abordar, é a aplicação dos atuais métodos avançados de aprendizagem de máquinas, neste caso a aprendizagem profunda (LECUN; BENGIO; HINTO, 2015), ao mesmo problema abordado neste trabalho. As abordagens de aprendizagem profunda, conhecidas como redes neurais convolucionais (CNN), ou também na utilização de outros modelos também profundos, revolucionaram o campo da Visão Computacional. Servindo como exemplo DeepFace (TAIGMAN *et al.*, 2014), uma CNN desenvolvida por pesquisadores de instituto de pesquisa de redes sociais que alcançou resultados à nível humano em tarefas de verificação facial, ou HyperFace (RANJAN; PATEL; CHELLAPPA, 2017) que conseguiu localizar automaticamente pontos faciais (não cefalométricos), a pose do rosto e o sexo dos indivíduos

em poses aleatórias, com a base de dados atual.

O conjunto metodológico proposto apresentou múltiplas vantagens em relação à literatura científica disponível. No entanto, traduzi-lo para a prática requer implementações cuidadosas e acompanhamento de atualizações em evidências científicas. Estudos futuros no campo devem testar a reprodutibilidade dessa configuração metodológica e os resultados inerentes em diferentes populações. Investigações baseadas em outros limites de idade legal também são encorajadas a melhor se adequar aos sistemas judiciais de diferentes países. A implementação de um *software* e uso da metodologia de estimação de idade em casos reais é indicada como uma ferramenta para auxiliar os profissionais que combatem casos de pedofilia em pornografia. Avanços na configuração metodológica para novas melhorias devem incluir amostragem longitudinal e imagem tridimensional.

Outra abordagem no campo de Visão Computacional é avaliar o uso de plataformas automáticas para criação da melhor arquitetura para um conjunto de dados, como AutoML (Google LLC, 2018) e AutoKeras (JIN; SONG; HU, 2018), podendo ser utilizadas para encontrar uma nova arquitetura específica para a abordagem combinada (imagens e RFAs) com um melhor resultado ao contrário de se utilizar uma arquitetura proposta em outros trabalhos.

6.2 PUBLICAÇÕES REALIZADAS

- **PORTO, LUCAS FARIA;** CORREIA LIMA, LAISE NASCIMENTO; PINHEIRO FLORES, MARTA REGINA; VALSECCHI, ANDREA; IBANEZ, OSCAR; M. PALHARES, CARLOS EDUARDO; DE BARROS VIDAL, FLAVIO . *Automatic cephalometric landmarks detection on frontal faces: An approach based on supervised learning techniques*. Digital Investigation, v.30, p.108-116, 2019, JCR 1,771.
- FORTES, A. B. C.; LIMA, L. N. C.; SANTIAGO, B. M.; **PORTO, L. F.;** FRANCO, A.; DARUGE JUNIOR, E. ; MACHADO, C. E. P. . *Análise fotoantropométrica da alometria de crescimento facial humano em crianças, adolescentes e subadultos brasileiros*. In: XXV Congresso Nacional De Criminalística, VIII Congresso Internacional De Perícia Criminal e Da XXV Exposição De Tecnologias Aplicadas À Criminalística, 2019, Goiânia. 25º Congresso Nacional De Criminalística, 2019.
- BICALHO, G. C.; ALVES, M. C. A.; **PORTO, L. F.;** MACHADO, C. E. P.; VIDAL, F. B. . *Solving the face growth problem in the biometric face recognition using Photo-Anthropometric Ratios by Iris Normalization*. In: International Workshop on Biometrics and Forensics (IWBF), 2018, Sassari. 6th IWBF - International Workshop on Biometrics and Forensics, 2018.
- LIMA, L. N. C.; **PORTO, L. F.;** SANTIAGO, B. M.; INMACULADA, A. A.; MACHADO, C. E. P.; DARUGE JUNIOR, E. . *Patrón morfológico de crecimiento facial*

en individuos brasileños: análisis fotoantropométrico. In: IX JORNADAS AEAOF Y IX REUNIÓN SOFIA, 2017, Huelva. LIBRO DE RESÚMENES - IX JORNADAS AEAOF Y IX REUNIÓN SOFIA, 2017. p. 32-32.

Por último, o autor e orientador desta tese de doutorado gostariam de agradecer à equipe da Polícia Federal (PF), especialmente aos peritos do Instituto Nacional de Criminalística (INC). Este trabalho foi apoiado e financiado pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e Polícia Federal do Brasil (Edital Pro-Forenses 25/2014 CAPES - Código de Financiamento 001).

REFERÊNCIAS BIBLIOGRÁFICAS

- ABADI, M.; AGARWAL, A.; BARHAM, P.; BREVD, E.; CHEN, Z.; CITRO, C.; CORRADO, G. S.; DAVIS, A.; DEAN, J.; DEVIN, M.; GHEMAWAT, S.; GOODFELLOW, I.; HARP, A.; IRVING, G.; ISARD, M.; JIA, Y.; JOZEFOWICZ, R.; KAISER, L.; KUDLUR, M.; LEVENBERG, J.; MANÉ, D.; MONGA, R.; MOORE, S.; MURRAY, D.; OLAH, C.; SCHUSTER, M.; SHLENS, J.; STEINER, B.; SUTSKEVER, I.; TALWAR, K.; TUCKER, P.; VANHOUCHE, V.; VASUDEVAN, V.; VIÉGAS, F.; VINYALS, O.; WARDEN, P.; WATTENBERG, M.; WICKE, M.; YU, Y.; ZHENG, X. *TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems*. 2015. Software available from [tensorflow.org](https://www.tensorflow.org/). Disponível em: <<https://www.tensorflow.org/>>.
- ADSERIAS-GARRIGA, J.; THOMAS, C.; UBELAKER, D. H.; ZAPICO, S. C. When forensic odontology met biochemistry: Multidisciplinary approach in forensic human identification. *Archives of oral biology*, Elsevier, v. 87, p. 7–14, 2018.
- AFIFI, M.; ABDELHAMED, A. Afif4: deep gender classification based on adaboost-based fusion of isolated facial features and foggy faces. *Journal of Visual Communication and Image Representation*, Elsevier, v. 62, p. 77–86, 2019.
- ANDA, F.; LILLIS, D.; KANTA, A.; BECKER, B. A.; BOU-HARB, E.; LE-KHAC, N.-A.; SCANLON, M. Improving borderline adulthood facial age estimation through ensemble learning. In: ACM. *Proceedings of the 14th International Conference on Availability, Reliability and Security*. [S.l.], 2019. p. 57.
- ANDA, F.; LILLIS, D.; LE-KHAC, N.-A.; SCANLON, M. Evaluating automated facial age estimation techniques for digital forensics. In: IEEE. *2018 IEEE Security and Privacy Workshops (SPW)*. [S.l.], 2018. p. 129–139.
- ANGULU, R.; TAPAMO, J. R.; ADEWUMI, A. O. Age estimation via face images: a survey. *EURASIP Journal on Image and Video Processing*, Springer, v. 2018, n. 1, p. 42, 2018.
- APELAND, S. *Intel AI DevCloud*. <<https://www.intel.ai/devcloud/>>. Accessed: 2019-01-22. Disponível em: <<https://www.intel.ai/devcloud/>>.
- AULSEBROOK, W.; IŞCAN, M.; SLABBERT, J.; BECKER, P. Superimposition and reconstruction in forensic facial identification: a survey. *Forensic Science International*, Elsevier, v. 75, n. 2-3, p. 101–120, 1995.
- BEKHOUCHE, S. E.; OUAFI, A.; TALEB-AHMED, A.; HADID, A.; BENLAMOUDI, A. Facial age estimation using bsif and lbp. *arXiv preprint arXiv:1601.01876*, 2016.
- BICALHO, G. C.; ALVES, M. C. A.; PORTO, L. F.; MACHADO, C. E. P.; VIDAL, F. de B. Solving the face growth problem in the biometric face recognition using photo-anthropometric ratios by iris normalization. In: *2018 International Workshop on Biometrics and Forensics (IWBF)*. [S.l.: s.n.], 2018. p. 1–6.
- BOOKSTEIN, F. *Morphometric tools for landmark data. Geometry and biology*. [S.l.]: Cambridge University Press, Cambridge, 1991.

- BORGES, D. L.; VIDAL, F. B.; FLORES, M. R.; MELANI, R. F.; GUIMARÃES, M. A.; MACHADO, C. E. Photoanthropometric face iridial proportions for age estimation: An investigation using features selected via a joint mutual information criterion. *Forensic Science International*, v. 284, p. 9 – 14, 2018.
- BROWN, R. E.; KELLIHER, T. P.; TU, P. H.; TURNER, W. D.; TAISTER, M. A.; MILLER, K. W. A survey of tissue-depth landmarks for facial approximation. *Forensic Sci. Commun*, v. 6, n. 1, 2004.
- BURGOS-ARTIZZU, X. P.; PERONA, P.; DOLLÁR, P. Robust face landmark estimation under occlusion. In: *2013 IEEE International Conference on Computer Vision*. [S.l.: s.n.], 2013. p. 1513–1520. ISSN 1550-5499.
- BUSCHANG, P. H.; TANGUAY, R.; DEMIRJIAN, A. Cephalometric reliability: a full anova model for the estimation of true and error variance. *The Angle orthodontist*, v. 57, n. 2, p. 168–175, 1987.
- CAMPOMANES-ÁLVAREZ, B.; IBÁÑEZ, O.; NAVARRO, F.; ALEMÁN, I.; CORDÓN, O.; DAMAS, S. Dispersion assessment in the location of facial landmarks on photographs. *International journal of legal medicine*, Springer, v. 129, n. 1, p. 227–236, 2015.
- CAMPOMANES-ÁLVAREZ, B. R.; IBÁÑEZ, O.; NAVARRO, F.; BOTELLA, M.; DAMAS, S.; CORDÓN, O. Computer vision and soft computing for automatic skull–face overlay in craniofacial superimposition. *Forensic Science International*, Elsevier, v. 245, p. 77–86, 2014.
- CAMPOMANES-ÁLVAREZ, C.; MARTOS-FERNÁNDEZ, R.; WILKINSON, C.; IBÁÑEZ, O.; CORDÓN, O. Modeling skull-face anatomical/morphological correspondence for craniofacial superimposition-based identification. *IEEE Transactions on Information Forensics and Security*, v. 13, n. 6, p. 1481–1494, 2018.
- CAO, Q.; SHEN, L.; XIE, W.; PARKHI, O. M.; ZISSERMAN, A. Vggface2: A dataset for recognising faces across pose and age. In: IEEE. *2018 13th IEEE International Conference on Automatic Face & Gesture Recognition (FG 2018)*. [S.l.], 2018. p. 67–74.
- CAPLE, J.; STEPHAN, C. A standardized nomenclature for craniofacial and facial anthropology. *International Journal of Legal Medicine*, v. 130, n. 3, p. 863–879, 2016.
- CAPPELLA, A.; GIBELLI, D.; OBERTOVIÁ, Z.; CUMMAUDO, M.; CASTOLDI, E.; ANGELIS, D. D.; SFORZA, C.; CATTANEO, C. The utility of skeletal and surgical features for the personal identification process: A pilot study. *Journal of Forensic Sciences*, Wiley Online Library, 2019.
- CARPENTER, B.; O'BRIEN, E.; HAYES, S.; DEATH, J. Harm, responsibility, age, and consent. *New Criminal Law Review: In International and Interdisciplinary Journal*, University of California Press, v. 17, n. 1, p. 23–54, 2014.
- CASTELLS, M. *A Galáxia Internet: reflexões sobre a Internet, negócios e a sociedade*. [S.l.]: Zahar, 2003.
- CATTANEO, C.; OBERTOVIÁ, Z.; RATNAYAKE, M.; MARASCIUOLO, L.; TUTKUVIENE, J.; POPPA, P.; GIBELLI, D.; GABRIEL, P.; RITZ-TIMME, S. Can facial

proportions taken from images be of use for ageing in cases of suspected child pornography? a pilot study. *International journal of legal medicine*, Springer, v. 126, n. 1, p. 139–144, 2012.

CATTANEO, C.; RITZ-TIMME, S.; GABRIEL, P.; GIBELLI, D.; GIUDICI, E.; POPPA, P.; NOHRDEN, D.; ASSMANN, S.; SCHMITT, R.; GRANDI, M. The difficult issue of age assessment on pedo-pornographic material. *Forensic science international*, Elsevier, v. 183, n. 1, p. e21–e24, 2009.

CECH, J.; FRANC, V.; MATAS, J. A 3d approach to facial landmarks: Detection, refinement, and tracking. In: IEEE. *Pattern Recognition (ICPR), 2014 22nd International Conference on*. [S.l.], 2014. p. 2173–2178.

ÇELIKTUTAN, O.; ULUKAYA, S.; SANKUR, B. A comparative study of face landmarking techniques. *EURASIP Journal on Image and Video Processing*, v. 2013, n. 1, p. 13, Mar 2013.

CERICATO, G. O.; FRANCO, A.; BITTENCOURT, M. A. V.; NUNES, M. A. P.; PARANHOS, L. R. Correlating skeletal and dental developmental stages using radiographic parameters. *Journal of forensic and legal medicine*, Elsevier, v. 42, p. 13–18, 2016.

CHEN, B.-C.; CHEN, C.-S.; HSU, W. H. Face recognition and retrieval using cross-age reference coding with cross-age celebrity dataset. *IEEE Transactions on Multimedia*, IEEE, v. 17, n. 6, p. 804–815, 2015.

CHEN, C.; QIU, M.; YANG, Y.; ZHOU, J.; HUANG, J.; LI, X.; BAO, F. S. Multi-domain gated cnn for review helpfulness prediction. In: ACM. *The World Wide Web Conference*. [S.l.], 2019. p. 2630–2636.

CHEN, J.-C.; KUMAR, A.; RANJAN, R.; PATEL, V. M.; ALAVI, A.; CHELLAPPA, R. A cascaded convolutional neural network for age estimation of unconstrained faces. In: IEEE. *Biometrics Theory, Applications and Systems (BTAS), 2016 IEEE 8th International Conference on*. [S.l.], 2016. p. 1–8.

CHEN, J. C.; PATEL, V. M.; HO, H. T.; CHELLAPPA, R. Dictionary-based video face recognition using dense multi-scale facial landmark features. In: *2014 IEEE International Conference on Image Processing (ICIP)*. [S.l.: s.n.], 2014. p. 733–737.

CHOLLET, F. *et al. Keras*. 2015. <https://keras.io>.

CIREGAN, D.; MEIER, U.; SCHMIDHUBER, J. Multi-column deep neural networks for image classification. In: IEEE. *Computer Vision and Pattern Recognition (CVPR), 2012 IEEE Conference on*. [S.l.], 2012. p. 3642–3649.

CUMMAUDO, M.; GUERZONI, M.; GIBELLI, D.; CIGADA, A.; OBERTOVÀ, Z.; RATNAYAKE, M.; POPPA, P.; GABRIEL, P.; RITZ-TIMME, S.; CATTANEO, C. Towards a method for determining age ranges from faces of juveniles on photographs. *Forensic science international*, Elsevier, v. 239, p. 107–e1, 2014.

CUMMAUDO, M.; GUERZONI, M.; MARASCIUOLO, L.; GIBELLI, D.; CIGADA, A.; OBERTOVÀ, Z.; RATNAYAKE, M.; POPPA, P.; GABRIEL, P.; RITZ-TIMME, S. *et al.* Pitfalls at the root of facial assessment on photographs: a quantitative study of accuracy in

positioning facial landmarks. *International journal of legal medicine*, Springer, v. 127, n. 3, p. 699–706, 2013.

DALAL, N.; TRIGGS, B. Histograms of oriented gradients for human detection. In: *IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*. [S.l.: s.n.], 2005. v. 1, p. 886–893.

DAVIS, J. P.; VALENTINE, T.; DAVIS, R. E. Computer assisted photo-anthropometric analyses of full-face and profile facial images. *Forensic science international*, Elsevier, v. 200, n. 1, p. 165–176, 2010.

DEITOS, A. R.; COSTA, C.; MICHEL-CROSATO, E.; GALIĆ, I.; CAMERIERE, R.; BIAZEVIC, M. G. H. Age estimation among brazilians: younger or older than 18? *Journal of forensic and legal medicine*, Elsevier, v. 33, p. 111–115, 2015.

DELONG, E. R.; DELONG, D. M.; CLARKE-PEARSON, D. L. Comparing the areas under two or more correlated receiver operating characteristic curves: a nonparametric approach. *Biometrics*, v. 44, n. 3, p. 837–845, 1988.

DEMAYO, C.; TORRES, M.; SINCO, A.; BONACHITA-SANGUILA, M. Geometric morphometric analyses of facial shape in twins. *The Internet Journal of Biological Anthropology*, v. 4, n. 1, 2010.

DENG, J.; GUO, J.; XUE, N.; ZAFEIRIOU, S. Arcface: Additive angular margin loss for deep face recognition. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2019. p. 4690–4699.

DHIMAR, T.; MISTREE, K. Feature extraction for facial age estimation: A survey. In: IEEE. *Wireless Communications, Signal Processing and Networking (WiSPNET), International Conference on*. [S.l.], 2016. p. 2243–2248.

DIBEKLIOGLU, H.; ALNAJAR, F.; SALAH, A. A.; GEVERS, T. Combining facial dynamics with appearance for age estimation. *Image Processing, IEEE Transactions on*, IEEE, v. 24, n. 6, p. 1928–1943, 2015.

EDMONDS, A. Triumphant miscegenation: Reflections on beauty and race in brazil. *Journal of Intercultural Studies*, Taylor & Francis, v. 28, n. 1, p. 83–97, 2007.

EL-BIALY, A. Towards a complete computer dental treatment system. In: IEEE. *2008 Cairo International Biomedical Engineering Conference*. [S.l.], 2008. p. 1–8.

EL-MANGOURY, N. H.; SHAHEEN, S. I.; MOSTAFA, Y. A. Landmark identification in computerized posteroanterior cephalometrics. *American Journal of Orthodontics and Dentofacial Orthopedics*, Elsevier, v. 91, n. 1, p. 57–61, 1987.

EO, T.; JUN, Y.; KIM, T.; JANG, J.; LEE, H.-J.; HWANG, D. Kiki-net: cross-domain convolutional neural networks for reconstructing undersampled magnetic resonance images. *Magnetic resonance in medicine*, Wiley Online Library, v. 80, n. 5, p. 2188–2201, 2018.

ESCALERA, S.; FABIAN, J.; PARDO, P.; BARO, X.; GONZALEZ, J.; ESCALANTE, H.; GUYON, I. Chalearn 2015 apparent age and cultural event recognition: datasets and results. In: *ICCV, ChaLearn Looking at People workshop*. [S.l.: s.n.], 2015. v. 1, n. 3, p. 4.

- FANG, J.; YUAN, Y.; LU, X.; FENG, Y. Multi-stage learning for gender and age prediction. *Neurocomputing*, Elsevier, v. 334, p. 114–124, 2019.
- FARKAS, L. G.; KATIC, M. J.; FORREST, C. R. International anthropometric study of facial morphology in various ethnic groups/races. *Journal of Craniofacial Surgery*, LWW, v. 16, n. 4, p. 615–646, 2005.
- FLORES, M. R. P. *Proposta de metodologia de análise fotoantropométrica para identificação humana em imagens faciais em norma frontal*. Dissertação (Mestrado) — Faculdade de Odontologia de Ribeirão Preto, Universidade de São Paulo, 2014.
- FLORES, M. R. P.; MACHADADO, C. E. P. *Manual of facial photo-anthropometry: Visual References for landmark positioning in frontal view images*. [S.l.], abr. 2018. SUPPORT By: Edmar Antônio da Silva - SAFF-2D Programming Audiovisual and Electronic Skills Service of the National Institute of Criminalistics (SEPAEL/INC). Disponível em: <http://facisgroup.org/facial_landmarks>.
- FLORES, M. R. P.; MACHADO, C. E. P.; GALLIDABINO, M. D.; ARRUDA, G. H. M. de; SILVA, R. H. A. da; VIDAL, F. B. de; MELANI, R. F. H. Comparative assessment of a novel photo-anthropometric landmark-positioning approach for the analysis of facial structures on two-dimensional images. *Journal of Forensic Sciences*, v. 64, n. 3, p. 828–838, 2019. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/1556-4029.13935>>.
- FRANÇA, G. V. d. Medicina legal. 6ª edição. *Koogan*, v. 2, p. 35, 2001.
- FRANCISCO, R. A.; VELLOSO, A. P.; SILVEIRA, T. C.; SECCHIER, J. M.; GUIMARÃES, M. A. Antropologia forense no centro de medicina legal da fmrp/usp, estudo comparativo de casos de 1999-2009. *Medicina (Ribeirão Preto. Online)*, v. 44, n. 3, p. 241–248, 2011.
- FRANCO, A.; THEVISSSEN, P.; FIEUWS, S.; SOUZA, P. H. C.; WILLEMS, G. Applicability of willems model for dental age estimations in brazilian children. *Forensic science international*, Elsevier, v. 231, n. 1-3, p. 401–e1, 2013.
- FU, Y.; GUO, G.; HUANG, T. S. Age synthesis and estimation via faces: A survey. *IEEE transactions on pattern analysis and machine intelligence*, IEEE, v. 32, n. 11, p. 1955–1976, 2010.
- FU, Y.; HOSPEDALES, T. M.; XIANG, T.; YAO, Y.; GONG, S. Interestingness prediction by robust learning to rank. In: *ECCV*. [S.l.: s.n.], 2014.
- FU, Y.; HUANG, T. S. Human age estimation with regression on discriminative aging manifold. *IEEE Transactions on Multimedia*, IEEE, v. 10, n. 4, p. 578–584, 2008.
- GALLAGHER, A.; CHEN, T. Understanding images of groups of people. In: *Proc. CVPR*. [S.l.: s.n.], 2009.
- GANEL, T. Smiling makes you look older. *Psychonomic bulletin & review*, Springer, v. 22, n. 6, p. 1671–1677, 2015.
- GENG, X.; ZHOU, Z.-H.; SMITH-MILES, K. Automatic age estimation based on facial aging patterns. *IEEE Transactions on pattern analysis and machine intelligence*, IEEE, v. 29, n. 12, p. 2234–2240, 2007.

- GHAHARI, A.; MOSLEH, M. Hybrid clustering-based 3d face modeling upon non-perfect orthogonality of frontal and profile views. In: IEEE. *Computer Information Systems and Industrial Management Applications (CISIM), 2010 International Conference on*. [S.l.], 2010. p. 578–584.
- GIBELLI, D.; OBERTOVIĆ, Z.; RITZ-TIMME, S.; GABRIEL, P.; ARENT, T.; RATNAYAKE, M.; ANGELIS, D. D.; CATTANEO, C. The identification of living persons on images: A literature review. *Legal Medicine*, Elsevier, v. 19, p. 52–60, 2016.
- GOLOMB, B. A.; LAWRENCE, D. T.; SEJNOWSKI, T. J. Sexnet: A neural network identifies sex from human faces. In: *NIPS*. [S.l.: s.n.], 1990. v. 1, p. 2.
- GONZALES, P. S.; MACHADO, C. E. P.; MICHEL-CROSATO, E. Photoanthropometry of the face in the young white brazilian population. *Brazilian dental journal*, SciELO Brasil, v. 29, n. 6, p. 619–623, 2018.
- Google LLC. *Cloud AutoML*. 2018. <<https://cloud.google.com/automl/>>. Acessado: 10/10/2019. Disponível em: <<https://cloud.google.com/automl/>>.
- GRAUPNER, H. Sexual consent: The criminal law in europe and overseas. *Archives of Sexual Behavior*, Springer, v. 29, n. 5, p. 415–461, 2000.
- GRD, P.; BAČA, M. Creating a face database for age estimation and classification. In: *39th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)*. [S.l.]: IEEE, 2016.
- GUO, G.; MU, G.; FU, Y.; HUANG, T. S. Human age estimation using bio-inspired features. In: IEEE. *2009 IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.], 2009. p. 112–119.
- HAN, H.; JAIN, A. K.; WANG, F.; SHAN, S.; CHEN, X. Heterogeneous face attribute estimation: A deep multi-task learning approach. *IEEE transactions on pattern analysis and machine intelligence*, IEEE, v. 40, n. 11, p. 2597–2609, 2017.
- HAN, H.; OTTO, C.; JAIN, A. K. Age estimation from face images: Human vs. machine performance. In: IEEE. *2013 International Conference on Biometrics (ICB)*. [S.l.], 2013. p. 1–8.
- HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. *The elements of statistical learning: data mining, inference and prediction*. 2. ed. Springer, 2009. Disponível em: <<http://www-stat.stanford.edu/~tibs/ElemStatLearn/>>.
- HAYASHI, J.-i.; YASUMOTO, M.; ITO, H.; KOSHIMIZU, H. Age and gender estimation based on wrinkle texture and color of facial images. In: IEEE. *Object recognition supported by user interaction for service robots*. [S.l.], 2002. v. 1, p. 405–408.
- HE, K.; ZHANG, X.; REN, S.; SUN, J. Deep residual learning for image recognition. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2016. p. 770–778.
- HENNESSY, R. J.; STRINGER, C. B. Geometric morphometric study of the regional variation of modern human craniofacial form. *American Journal of Physical Anthropology: The Official Publication of the American Association of Physical Anthropologists*, Wiley Online Library, v. 117, n. 1, p. 37–48, 2002.

- HENSS, R. Perceiving age and attractiveness in facial photographs 1. *Journal of Applied Social Psychology*, Wiley Online Library, v. 21, n. 11, p. 933–946, 1991.
- HOSSAIN, M. S.; MUHAMMAD, G. Emotion recognition using deep learning approach from audio–visual emotional big data. *Information Fusion*, Elsevier, v. 49, p. 69–78, 2019.
- HUANG, G. B.; MATTAR, M.; BERG, T.; LEARNED-MILLER, E. Labeled faces in the wild: A database for studying face recognition in unconstrained environments. In: . [S.l.: s.n.], 2008.
- HUBER, P.; FENG, Z.-H.; CHRISTMAS, W.; KITTLER, J.; RÄTSCHE, M. Fitting 3d morphable face models using local features. In: IEEE. *Image Processing (ICIP), 2015 IEEE International Conference on*. [S.l.], 2015. p. 1195–1199.
- IDADE, E. D. Estimativa da idade pelos 3º molares através de rx: relato de caso. *RGO*, v. 54, n. 3, p. 230–233, 2006.
- IGA, R.; IZUMI, K.; HAYASHI, H.; FUKANO, G.; OHTANI, T. A gender and age estimation system from face images. In: IEEE. *SICE 2003 Annual Conference (IEEE Cat. No. 03TH8734)*. [S.l.], 2003. v. 1, p. 756–761.
- INSAFUTDINOV, E.; PISHCHULIN, L.; ANDRES, B.; ANDRILUKA, M.; SCHIELE, B. Deepcrut: A deeper, stronger, and faster multi-person pose estimation model. In: SPRINGER. *European Conference on Computer Vision*. [S.l.], 2016. p. 34–50.
- International Organization for Standardization. *ISO/IEC 19794-5: Information technology – Biometric data interchange formats – Part 5: Face image data*. [S.l.], mar. 2005. v. 2005.
- INTERPOL. *INTERPOL Disaster Victim Identification Guide*. 2018. <<https://www.interpol.int/INTERPOL-expertise/Forensics/DVI-Pages/DVI-guide>>. Disponível em: <<https://www.interpol.int/>>.
- JAIN, A.; HUANG, J. Integrating independent components and linear discriminant analysis for gender classification. In: IEEE. *Automatic Face and Gesture Recognition, 2004. Proceedings. Sixth IEEE International Conference on*. [S.l.], 2004. p. 159–163.
- JAIN, L. C.; HALICI, U.; HAYASHI, I.; LEE, S.; TSUTSUI, S. *Intelligent biometric techniques in fingerprint and face recognition*. [S.l.]: CRC press, 1999.
- JAIN, V.; LEARNED-MILLER, E. G. Fddb: A benchmark for face detection in unconstrained settings. *UMass Amherst Technical Report*, 2010.
- JIA, Y.; SHELHAMER, E.; DONAHUE, J.; KARAYEV, S.; LONG, J.; GIRSHICK, R.; GUADARRAMA, S.; DARRELL, T. Caffe: Convolutional architecture for fast feature embedding. *arXiv preprint arXiv:1408.5093*, 2014.
- JIN, H.; SONG, Q.; HU, X. Auto-keras: Efficient neural architecture search with network morphism. In: . [S.l.: s.n.], 2018.
- KHAN, K.; ATTIQUE, M.; SYED, I.; GUL, A. Automatic gender classification through face segmentation. *Symmetry*, Multidisciplinary Digital Publishing Institute, v. 11, n. 6, p. 770, 2019.

- KIM, D. H.; KIM, Y. C. Wilcoxon signed rank test using ranked-set sample. *Korean Journal of Computational & Applied Mathematics*, v. 3, n. 2, p. 235–243, Jun 1996. ISSN 1865-2085. Disponível em: <<https://doi.org/10.1007/BF03008904>>.
- KING, D. E. Dlib-ml: A machine learning toolkit. *Journal of Machine Learning Research*, v. 10, p. 1755–1758, 2009.
- KINGMA, D. P.; BA, J. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, 2014.
- KLEINBERG, K. F.; VANEZIS, P.; BURTON, A. M. Failure of anthropometry as a facial identification technique using high-quality photographs. *Journal of forensic sciences*, Wiley Online Library, v. 52, n. 4, p. 779–783, 2007.
- KLIMENTIDIS, Y. C.; SHRIVER, M. D. Estimating genetic ancestry proportions from faces. *PLoS One*, Public Library of Science, v. 4, n. 2, p. e4460, 2009.
- KLOESS, J. A.; WOODHAMS, J.; WHITTLE, H.; GRANT, T.; HAMILTON-GIACHRITSIS, C. E. The challenges of identifying and classifying child sexual abuse material. *Sexual Abuse*, Sage Publications Sage CA: Los Angeles, CA, p. 1079063217724768, 2017.
- KOHAVI, R. *et al.* A study of cross-validation and bootstrap for accuracy estimation and model selection. In: STANFORD, CA. *Ijcai*. [S.l.], 1995. v. 14, p. 1137–1145.
- KOUDELOVÁ, J.; HOFFMANNOVÁ, E.; DUPEJ, J.; VELEMÍNSKÁ, J. Simulation of facial growth based on longitudinal data: Age progression and age regression between 7 and 17 years of age using 3d surface data. *PloS one*, Public Library of Science, v. 14, n. 2, p. e0212618, 2019.
- KRISHAN, K.; CHATTERJEE, P. M.; KANCHAN, T.; KAUR, S.; BARYAH, N.; SINGH, R. A review of sex estimation techniques during examination of skeletal remains in forensic anthropology casework. *Forensic science international*, Elsevier, v. 261, p. 165–e1, 2016.
- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. In: *Advances in neural information processing systems*. [S.l.: s.n.], 2012. p. 1097–1105.
- KUTNER, M. *Applied Linear Statistical Models*. McGraw-Hill Irwin, 2005. (McGrwa-Hill international edition). ISBN 9780071122214. Disponível em: <<https://books.google.com.br/books?id=0xqCAAAACAAJ>>.
- KWON, Y. H.; LOBO, N. da V. Age classification from facial images. In: IEEE. *Computer Vision and Pattern Recognition, 1994. Proceedings CVPR'94., 1994 IEEE Computer Society Conference on*. [S.l.], 1994. p. 762–767.
- LANITIS, A. On the significance of different facial parts for automatic age estimation. In: IEEE. *2002 14th International Conference on Digital Signal Processing Proceedings. DSP 2002 (Cat. No. 02TH8628)*. [S.l.], 2002. v. 2, p. 1027–1030.
- LANITIS, A.; HILL, A.; COOTES, T.; TAYLOR, C. Locating facial features using genetic algorithms. In: *International Conference on Digital Signal Processing*. [S.l.: s.n.], 1995. p. 520–525.

- LANITIS, A.; TAYLOR, C. J.; COOTES, T. F. Toward automatic simulation of aging effects on face images. *IEEE Transactions on pattern Analysis and machine Intelligence*, IEEE, v. 24, n. 4, p. 442–455, 2002.
- LE-TIEN, T.; PHAM-CHI, H. An approach for efficient detection of cephalometric landmarks. *Procedia Computer Science*, Elsevier, v. 37, p. 293–300, 2014.
- LECUN, Y.; BENGIO, Y.; HINTO, G. Deep learning. *Nature*, v. 521, p. 436–444, 2015.
- LEE, S. H.; RO, Y. M. Local age group modeling in unconstrained face images for facial age classification. In: IEEE. *Image Processing (ICIP), 2014 IEEE International Conference on*. [S.l.], 2014. p. 1395–1399.
- LEVI, G.; HASSNER, T. Age and gender classification using convolutional neural networks. In: *IEEE Conf. on Computer Vision and Pattern Recognition (CVPR) workshops*. [s.n.], 2015. Disponível em: <[url{http://www.openu.ac.il/home/hassner/projects/cnn_agegender}](http://www.openu.ac.il/home/hassner/projects/cnn_agegender)>.
- LI, K.; XING, J.; HU, W.; MAYBANK, S. J. D2c: Deep cumulatively and comparatively learning for human age estimation. *Pattern Recognition*, Elsevier, v. 66, p. 95–105, 2017.
- LIANG, B.; ZHAI, Y.; TONG, C.; ZHAO, J.; LI, J.; HE, X.; MA, Q. A deep automated skeletal bone age assessment model via region-based convolutional neural network. *Future Generation Computer Systems*, Elsevier, 2019.
- LIU, X.; LI, S.; KAN, M.; ZHANG, J.; WU, S.; LIU, W.; HAN, H.; SHAN, S.; CHEN, X. Agenet: Deeply learned regressor and classifier for robust apparent age estimation. In: *Proceedings of the IEEE International Conference on Computer Vision Workshops*. [S.l.: s.n.], 2015. p. 16–24.
- LIU, Z.; LUO, P.; WANG, X.; TANG, X. Deep learning face attributes in the wild. In: *Proceedings of the IEEE international conference on computer vision*. [S.l.: s.n.], 2015. p. 3730–3738.
- LUCAS, T.; KUMARATILAKE, J.; HENNEBERG, M. Metric identification of the same people from images: How reliable is it? *Journal of Anthropology*, Hindawi Publishing Corporation, v. 2016, 2016.
- MA, J.; AHUJA, N.; NETI, C.; SENIOR, A. W. Recovering frontal-pose image from a single profile image. In: IEEE. *Image Processing, 2000. Proceedings. 2000 International Conference on*. [S.l.], 2000. v. 2, p. 243–246.
- MACHADO, A. L. R.; DEZEM, T. U.; BRUNI, A. T.; SILVA, R. H. A. da. Age estimation by facial analysis based on applications available for smartphones. *The Journal of forensic odonto-stomatology*, International Organization of Forensic Odonto-Stomatology, v. 35, n. 2, p. 55, 2017.
- MACHADO, C.; FRANCISCO, R.; MARTIN, E.; GUIMARÃES, M. Combined use of photoantropometry and facial geometry in the investigation of child pornography in the internet. *World Forensic Festival - WFF*, p. 365–366, 2014.

- MACHADO, C. E. P. *Fotoantropometria para estimativa de idade de crianças e adolescentes com emprego de imagens faciais em norma frontal: relações iridianas*. Tese (Doutorado) — Departamento de Patologia e Medicina Legal da Faculdade de Medicina de Ribeirão Preto, Universidade de São Paulo, 2015.
- MACHADO, C. E. P.; FLORES, M. R. P.; LIMA, L. N. C.; TINOCO, R. L. R.; FRANCO, A.; BEZERRA, A. C. B.; EVISON, M. P.; GUIMARÃES, M. A. A new approach for the analysis of facial growth and age estimation: Iris ratio. *PLOS ONE*, Public Library of Science (PLoS), v. 12, n. 7, p. e0180330, 2017.
- MACHADO, C. E. P.; SANTIAGO, B. M.; LIMA, L. N. C.; GONZALES, P. S.; FRANCO, A.; VIDAL, F. de B.; AGUILERA, I. A.; GUIMARÃES, M. A. Applicability of a pre-established set of facial proportions from frontal photographs in forensic age estimation of a brazilian population. *Forensic Science International*, v. 301, p. e1 – e7, 2019. ISSN 0379-0738. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0379073819301859>>.
- MACHADO, M. A.; JÚNIOR, E. D.; FERNANDES, M. M.; LIMA, I. F. P.; CERICATO, G. O.; FRANCO, A.; PARANHOS, L. R. Effectiveness of three age estimation methods based on dental and skeletal development in a sample of young brazilians. *Archives of oral biology*, Elsevier, v. 85, p. 166–171, 2018.
- MAKINEN, E.; RAISAMO, R. Evaluation of gender classification methods with automatically detected and aligned faces. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, IEEE, v. 30, n. 3, p. 541–547, 2008.
- MARQUEZ-GRANT, N. An overview of age estimation in forensic anthropology: perspectives and practical considerations. *Annals of human biology*, Taylor & Francis, v. 42, n. 4, p. 308–322, 2015.
- MARSHALL, W. A.; TANNER, J. M. Variations in pattern of pubertal changes in girls. *Archives of disease in childhood*, BMJ Group, v. 44, n. 235, p. 291, 1969.
- MARTOS, R.; VALSECCHI, A.; IBÁÑEZ, O.; ALEMÁN, I. Estimation of 2d to 3d dimensions and proportionality indices for facial examination. *Forensic Science International*, v. 13, n. 6, p. 1481–1494, 2018.
- MATHIS, A.; MAMIDANNA, P.; CURY, K. M.; ABE, T.; MURTHY, V. N.; MATHIS, M. W.; BETHGE, M. *DeepLabCut: markerless pose estimation of user-defined body parts with deep learning*. [S.l.], 2018.
- MAYER, J. D.; GEHER, G. Emotional intelligence and the identification of emotion. *Intelligence*, Elsevier, v. 22, n. 2, p. 89–113, 1996.
- MONDAL, T.; JAIN, A.; SARDANA, H. Automatic craniofacial structure detection on cephalometric images. *Image Processing, IEEE Transactions on*, IEEE, v. 20, n. 9, p. 2606–2614, 2011.
- MORETON, R.; MORLEY, J. Investigation into the use of photoanthropometry in facial image comparison. *Forensic science international*, Elsevier, v. 212, n. 1, p. 231–237, 2011.

- MOSCHOGLOU, S.; PAPAIOANNOU, A.; SAGONAS, C.; DENG, J.; KOTSIA, I.; ZAFEIRIOU, S. Agedb: the first manually collected, in-the-wild age database. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*. [S.l.: s.n.], 2017. p. 51–59.
- MOSLEH, M. A.; BABA, M. S.; HIMAZIAN, N.; AL-MAKRAMANI, B. An image processing system for cephalometric analysis and measurements. In: *IEEE. Information Technology, 2008. ITSIM 2008. International Symposium on*. [S.l.], 2008. v. 4, p. 1–8.
- MOYSE, E.; BRÉDART, S. An own-age bias in age estimation of faces. *Revue Européenne de Psychologie Appliquée/European Review of Applied Psychology*, Elsevier, v. 62, n. 1, p. 3–7, 2012.
- NARANG, N.; BOURLAI, T. Gender and ethnicity classification using deep learning in heterogeneous face recognition. In: *IEEE. Biometrics (ICB), 2016 International Conference on*. [S.l.], 2016. p. 1–8.
- NATH, T.; MATHIS, A.; CHEN, A. C.; PATEL, A.; BETHGE, M.; MATHIS, M. W. Using deeplabcut for 3d markerless pose estimation across species and behaviors. *Nature protocols*, 2019.
- NETO, M. F.; GUIMARÃES, J. A. C. Crimes na internet: elementos para uma reflexão sobre a ética informacional. *Revista CEJ*, v. 7, n. 20, p. 67–73, 2003.
- NGUYEN, C. C.; TRAN, G. S.; NGHIEM, T. P.; BURIE, J.-C.; LUONG, C. M. Real-time smile detection using deep learning. *Journal of Computer Science and Cybernetics*, v. 35, n. 2, p. 135–145, 2019.
- NGUYEN, H.-T.; HUONG, T. T. N. Unconstrained gender classification by multi-resolution l_pq and sift. In: *IEEE. Information and Computer Science (NICS), 2016 3rd National Foundation for Science and Technology Development Conference on*. [S.l.], 2016. p. 212–217.
- NUNES, L. F. de M.; ZAGHETTO, C.; VIDAL, F. de B. 3d face recognition on point cloud data - an approaching based on curvature map projection using low resolution devices. In: *INSTICC. Proceedings of the 15th International Conference on Informatics in Control, Automation and Robotics - Volume 2: ICINCO*,. [S.l.]: SciTePress, 2018. p. 266–273. ISBN 978-989-758-321-6.
- PARKHI, O. M.; VEDALDI, A.; ZISSERMAN, A. *et al.* Deep face recognition. In: *bmvc*. [S.l.: s.n.], 2015. v. 1, n. 3, p. 6.
- PASZKE, A.; GROSS, S.; CHINTALA, S.; CHANAN, G.; YANG, E.; DEVITO, Z.; LIN, Z.; DESMAISON, A.; ANTIGA, L.; LERER, A. Automatic differentiation in PyTorch. In: *NIPS Autodiff Workshop*. [S.l.: s.n.], 2017.
- PATIL, K. R.; MODY, R. N. Determination of sex by discriminant function analysis and stature by regression analysis: a lateral cephalometric study. *Forensic science international*, Elsevier, v. 147, n. 2, p. 175–180, 2005.
- PHILLIPS, P. J.; MOON, H.; RIZVI, S.; RAUSS, P. J. *et al.* The feret evaluation methodology for face-recognition algorithms. *Pattern Analysis and Machine Intelligence, IEEE Transactions on, IEEE*, v. 22, n. 10, p. 1090–1104, 2000.

- PITTENGER, J. B.; SHAW, R. E. Perception of relative and absolute age in facial photographs. *Perception & Psychophysics*, Springer, v. 18, n. 2, p. 137–143, 1975.
- PORTO, L. F.; LIMA, L. N. C.; FLORES, M.; VALSECCHI, A.; IBANEZ, O.; PALHARES, C. E. M.; VIDAL, F. de B. Automatic cephalometric landmarks detection on frontal faces: An approach based on supervised learning techniques. *Digital Investigation*, 2019. ISSN 1742-2876. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1742287619301288>>.
- PRENDERGAST, P. M. Facial proportions. In: *Advanced Surgical Facial Rejuvenation*. [S.l.]: Springer, 2012. p. 15–22.
- PROVOST, F.; KOHAVI, R. On applied research in machine learning. In: *Machine learning*. [S.l.: s.n.], 1998. p. 127–132.
- RANJAN, R.; PATEL, V. M.; CHELLAPPA, R. Hyperface: A deep multi-task learning framework for face detection, landmark localization, pose estimation, and gender recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, p. 1–1, 2017.
- RANJAN, R.; SANKARANARAYANAN, S.; CASTILLO, C. D.; CHELLAPPA, R. An all-in-one convolutional neural network for face analysis. In: IEEE. *2017 12th IEEE International Conference on Automatic Face & Gesture Recognition (FG 2017)*. [S.l.], 2017. p. 17–24.
- RATNAYAKE, M.; OBERTOVÁ, Z.; DOSE, M.; GABRIEL, P.; BRÖKER, H.; BRAUCKMANN, M.; BARKUS, A.; RIZGELIENE, R.; TUTKUVIENE, J.; RITZ-TIMME, S. *et al.* The juvenile face as a suitable age indicator in child pornography cases: a pilot study on the reliability of automated and visual estimation approaches. *International journal of legal medicine*, Springer, v. 128, n. 5, p. 803–808, 2014.
- RAZAVIAN, A. S.; AZIZPOUR, H.; SULLIVAN, J.; CARLSSON, S. Cnn features off-the-shelf: an astounding baseline for recognition. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*. [S.l.: s.n.], 2014. p. 806–813.
- RICANEK, K.; TESAFAYE, T. Morph: A longitudinal image database of normal adult age-progression. In: IEEE. *7th International Conference on Automatic Face and Gesture Recognition (FGR06)*. [S.l.], 2006. p. 341–345.
- RONDEAU, J.; ALVAREZ, M. Deep modeling of human age guesses for apparent age estimation. In: IEEE. *2018 International Joint Conference on Neural Networks (IJCNN)*. [S.l.], 2018. p. 01–08.
- ROTHER, R.; TIMOFTE, R.; GOOL, L. V. Dex: Deep expectation of apparent age from a single image. In: *Proceedings of the IEEE International Conference on Computer Vision Workshops*. [S.l.: s.n.], 2015. p. 10–15.
- ROWE PAUL WILLNER, G. Alcohol servers' estimates of young people's ages. *Drugs: education, prevention and policy*, Taylor & Francis, v. 8, n. 4, p. 375–383, 2001.
- RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. *Learning internal representations by error propagation*. [S.l.], 1985.

- SAMAL, A.; IYENGAR, P. A. Automatic recognition and analysis of human faces and facial expressions: A survey. *Pattern recognition*, Elsevier, v. 25, n. 1, p. 65–77, 1992.
- SANTIAGO, B. M.; ALMEIDA, L.; CAVALCANTI, Y. W.; MAGNO, M. B.; MAIA, L. C. Accuracy of the third molar maturity index in assessing the legal age of 18 years: a systematic review and meta-analysis. *International journal of legal medicine*, Springer, v. 132, n. 4, p. 1167–1184, 2018.
- SAVAGE, A. W.; SHOWFETY, K. J.; YANCEY, J. Repeated measures analysis of geometrically constructed and directly determined cephalometric points. *American Journal of Orthodontics and Dentofacial Orthopedics*, Elsevier, v. 91, n. 4, p. 295–299, 1987.
- SCHMELING, A.; DETTMAYER, R.; RUDOLF, E.; VIETH, V.; GESERICK, G. Forensic age estimation: methods, certainty, and the law. *Deutsches Ärzteblatt International*, Deutscher Arzte-Verlag GmbH, v. 113, n. 4, p. 44, 2016.
- SCHMELING, A.; GESERICK, G.; REISINGER, W.; OLZE, A. Age estimation. *Forensic science international*, Elsevier, v. 165, n. 2, p. 178–181, 2007.
- SCHMELING, A.; OLZE, A.; REISINGER, W.; GESERICK, G. Age estimation of living people undergoing criminal proceedings. *The Lancet*, Elsevier, v. 358, n. 9276, p. 89–90, 2001.
- SHEN, W.; GUO, Y.; WANG, Y.; ZHAO, K.; WANG, B.; YUILLE, A. L. Deep regression forests for age estimation. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2018. p. 2304–2313.
- SHI, J.; SAMAL, A.; MARX, D. How effective are landmarks and their geometry for face recognition? *Computer Vision and Image Understanding*, Elsevier, v. 102, n. 2, p. 117–133, 2006.
- SILVA, R.; FRANCO, A.; DIAS, P.; GONÇALVES, A.; PARANHOS, L. Interrelationship between forensic radiology and forensic odontology—a case report of identified skeletal remains. *Journal of Forensic Radiology and Imaging*, Elsevier, v. 1, n. 4, p. 201–206, 2013.
- SILVA, R. F.; MENDES, S. D. S. C.; JÚNIOR, A. F. do R.; DIAS, P. E. M.; MARTORELL, L. B. Evidência documental x evidência biológica para estimativa da idade—relato de caso pericial. *Revista Odontológica do Brasil Central*, v. 22, n. 60, 2013.
- SOUZA, V. S. d. Science and miscegenation in the early twentieth century: Edgard roquette-pinto's debates and controversies with us physical anthropology. *História, Ciências, Saúde-Manguinhos*, SciELO Brasil, v. 23, n. 3, p. 597–614, 2016.
- STABRUN, A. E.; DANIELSEN, K. Precision in cephalometric landmark identification. *The European Journal of Orthodontics*, Oxford University Press, v. 4, n. 3, p. 185–196, 1982.
- STADELMANN, T.; TOLKACHEV, V.; SICK, B.; STAMPFLI, J.; DÜRR, O. Beyond imagenet: Deep learning in industrial practice. In: *Applied Data Science*. [S.l.]: Springer, 2019. p. 205–232.

- SUO, J.; ZHU, S.-C.; SHAN, S.; CHEN, X. A compositional and dynamic model for face aging. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, IEEE, v. 32, n. 3, p. 385–401, 2009.
- SZEGEDY, C.; IOFFE, S.; VANHOUCHE, V.; ALEMI, A. A. Inception-v4, inception-resnet and the impact of residual connections on learning. In: *Thirty-First AAAI Conference on Artificial Intelligence*. [S.l.: s.n.], 2017.
- TAHERI, S.; TOYGAR, Ö. On the use of dag-cnn architecture for age estimation with multi-stage features fusion. *Neurocomputing*, Elsevier, v. 329, p. 300–310, 2019.
- TAIGMAN, Y.; YANG, M.; RANZATO, M.; WOLF, L. Deepface: Closing the gap to human-level performance in face verification. In: *Computer Vision and Pattern Recognition (CVPR), IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2014. p. 1701–1708.
- TAN, M.; LE, Q. V. Efficientnet: Rethinking model scaling for convolutional neural networks. *arXiv preprint arXiv:1905.11946*, 2019.
- TAN, Z.; WAN, J.; LEI, Z.; ZHI, R.; GUO, G.; LI, S. Z. Efficient group-n encoding and decoding for facial age estimation. *IEEE transactions on pattern analysis and machine intelligence*, IEEE, v. 40, n. 11, p. 2610–2623, 2017.
- Theano Development Team. Theano: A Python framework for fast computation of mathematical expressions. *arXiv e-prints*, abs/1605.02688, maio 2016. Disponível em: <<http://arxiv.org/abs/1605.02688>>.
- THOMAZ, C. E.; GIRALDI, G. A. A new ranking method for principal components analysis and its application to face image analysis. *Image and Vision Computing*, Elsevier, v. 28, n. 6, p. 902–913, 2010.
- TONG, C.; LIANG, B.; LI, J.; ZHENG, Z. A deep automated skeletal bone age assessment model with heterogeneous features learning. *Journal of medical systems*, Springer, v. 42, n. 12, p. 249, 2018.
- UEKI, K.; HAYASHIDA, T.; KOBAYASHI, T. Subspace-based age-group classification using facial images under various lighting conditions. In: IEEE. *7th International Conference on Automatic Face and Gesture Recognition (FGR06)*. [S.l.], 2006. p. 6–pp.
- VALSECCHI, A.; DAMAS, S.; CORDÓN, O. A robust and efficient method for skull-face overlay in computerized craniofacial superimposition. *IEEE Transactions on Information Forensics and Security*, v. 13, n. 8, p. 1960–1974, 2018.
- VALSTAR, M. F.; JIANG, B.; MEHU, M.; PANTIC, M.; SCHERER, K. The first facial expression recognition and analysis challenge. In: IEEE. *Automatic Face & Gesture Recognition and Workshops (FG 2011), 2011 IEEE International Conference on*. [S.l.], 2011. p. 921–926.
- VERMA, V. K.; SRIVASTAVA, S.; JAIN, T.; JAIN, A. Local invariant feature-based gender recognition from facial images. In: *Soft Computing for Problem Solving*. [S.l.]: Springer, 2019. p. 869–878.

- VESTLUND, J.; LANGEORG, L.; SÖRQVIST, P.; ERIKSSON, M. Experts on age estimation. *Scandinavian Journal of Psychology*, Wiley Online Library, v. 50, n. 4, p. 301–307, 2009.
- VEZZETTI, E.; MARCOLIN, F.; FRACASTORO, G. 3d face recognition: An automatic strategy based on geometrical descriptors and landmarks. *Robotics and Autonomous Systems*, Elsevier, v. 62, n. 12, p. 1768–1776, 2014.
- VIOLA, P.; JONES, M. J. Robust real-time face detection. *International journal of computer vision*, Kluwer Academic Publishers, v. 57, n. 2, p. 137–154, 2004.
- VOELKLE, M. C.; EBNER, N. C.; LINDENBERGER, U.; RIEDIGER, M. Let me guess how old you are: Effects of age, gender, and facial expression on perceptions of age. *Psychology and aging*, American Psychological Association, v. 27, n. 2, p. 265, 2012.
- WAN, J.; TAN, Z.; LEI, Z.; GUO, G.; LI, S. Z. Auxiliary demographic information assisted age estimation with cascaded structure. *IEEE transactions on cybernetics*, IEEE, v. 48, n. 9, p. 2531–2541, 2018.
- WANG, J.; HE, X.; WANG, Z.; WU, J.; YUAN, N. J.; XIE, X.; XIONG, Z. Cd-cnn: a partially supervised cross-domain deep learning model for urban resident recognition. In: *Thirty-Second AAAI Conference on Artificial Intelligence*. [S.l.: s.n.], 2018.
- WANG, S.; TAO, D.; YANG, J. Relative attribute svm+ learning for age estimation. *IEEE transactions on cybernetics*, IEEE, v. 46, n. 3, p. 827–839, 2016.
- WILK, M. B.; SHAPIRO, S. S. An analysis of variance test for normality (complete samples). *Biometrika*, v. 52, n. 3-4, p. 591–611, 12 1965. ISSN 0006-3444. Disponível em: <<https://doi.org/10.1093/biomet/52.3-4.591>>.
- WISKOTT, L.; FELLOUS, J.-M.; KUIGER, N.; MALSBERG, C. V. D. Face recognition by elastic bunch graph matching. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, IEEE, v. 19, n. 7, p. 775–779, 1997.
- XIE, J.-C.; PUN, C.-M. Chronological age estimation under the guidance of age-related facial attributes. *IEEE Transactions on Information Forensics and Security*, IEEE, 2019.
- XING, J.; LI, K.; HU, W.; YUAN, C.; LING, H. Diagnosing deep learning models for high accuracy age estimation from a single image. *Pattern Recognition*, Elsevier, v. 66, p. 106–116, 2017.
- XIONG, X.; TORRE, F. De la. Supervised descent method and its applications to face alignment. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2013. p. 532–539.
- XIONG, X.; TORRE, F. De la. Global supervised descent method. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2015. p. 2664–2673.
- XU, C.; XU, Y.; MA, S. Cephalometric image measurement and prediction system. In: *IEEE. Instrumentation and Measurement Technology Conference, 1998. IMTC/98. Conference Proceedings. IEEE*. [S.l.], 1998. v. 1, p. 22–25.

- XU, L.; CHEN, J.; GAN, Y. Head pose estimation using deep multitask learning. *Journal of Electronic Imaging*, International Society for Optics and Photonics, v. 28, n. 1, p. 013029, 2019.
- YANG, H.; HUANG, D.; WANG, Y.; WANG, H.; TANG, Y. Face aging effect simulation using hidden factor analysis joint sparse representation. *IEEE Transactions on Image Processing*, IEEE, v. 25, n. 6, p. 2493–2507, 2016.
- YIP, B.; BINGHAM, G.; KEMPFERT, K.; FABISH, J.; KLING, T.; CHEN, C.; WANG, Y. Preliminary studies on a large face database. In: IEEE. *2018 IEEE International Conference on Big Data (Big Data)*. [S.l.], 2018. p. 2572–2579.
- ZHANG, L.; SHI, Z.; CHENG, M.-M.; LIU, Y.; BIAN, J.-W.; ZHOU, J. T.; ZHENG, G.; ZENG, Z. Robust regression via deep negative correlation learning. *arXiv preprint arXiv:1908.09066*, 2019.
- ZHAO, W.; CHELLAPPA, R.; PHILLIPS, P. J.; ROSENFELD, A. Face recognition: A literature survey. *ACM computing surveys (CSUR)*, ACM, v. 35, n. 4, p. 399–458, 2003.
- ZHU, G.; AA, S. van der. Trends of age of consent legislation in europe: A comparative study of 59 jurisdictions on the european continent. *New Journal of European Criminal Law*, SAGE Publications Sage UK: London, England, v. 8, n. 1, p. 14–42, 2017.
- ČECHOVÁ, M.; DUPEJ, J.; BRŮŽEKŠÁRKA, J.; BEJDOVÁ, S.; HORÁK, M.; VELEMÍNSKÁ, J. Sex estimation using external morphology of the frontal bone and frontal sinuses in a contemporary czech population. *International journal of legal medicine*, Springer, v. 133, n. 4, p. 1285–1294, 2019.

APÊNDICES

APÊNDICE A. RAZÕES FOTOANTROPOMÉTRICAS

Tabela A.1: Descrição das 208 razões fotoantropométricas (RFAs).

RFA	Landmarks	Descrição
RFA-0	al_r → al_l al_l → al_r	Comprimento do nariz
RFA-1	al_r → ch_r al_l → ch_l	Asa do nariz - Labial Commissure (Mesmo lado)
RFA-2	al_r → ch_l al_l → ch_r	Asa do nariz - Labial Commissure (Lados diferentes)
RFA-3	al_r → cph_r al_l → cph_l	Asa do nariz - Crista philtri (Mesmo lado)
RFA-4	al_r → cph_l al_l → cph_r	Asa do nariz - Crista philtri (Lados diferentes)
RFA-5	al_r → ec_r al_l → ec_l	Asa do nariz - Ectocanthion (Mesmo lado)
RFA-6	al_r → ec_l al_l → ec_r	Asa do nariz - Ectocanthion (Lados diferentes)
RFA-7	al_r → en_r al_l → en_l	Asa do nariz - Endocanthion (Mesmo lado)
RFA-8	al_r → en_l al_l → en_r	Asa do nariz - Endocanthion (Lados diferentes)
RFA-9	al_r → g al_l → g	Asa do nariz - Glabella
RFA-10	al_r → gn al_l → gn	Asa do nariz - Queixo
RFA-11	al_r → go_r al_l → go_l	Asa do nariz - Gonion (Mesmo lado)
RFA-12	al_r → go_l al_l → go_r	Asa do nariz - Gonion (Lados diferentes)
RFA-13	al_r → il_r al_l → il_l	Asa do nariz - Lateral iris (Mesmo lado)
RFA-14	al_r → il_l al_l → il_r	Asa do nariz - Lateral iris (Lados diferentes)
RFA-15	al_r → im_r al_l → im_l	Asa do nariz - Medial iris (Mesmo lado)
RFA-16	al_r → im_l al_l → im_r	Asa do nariz - Medial iris (Lados diferentes)
RFA-17	al_r → li al_l → li	Asa do nariz - Lábio inferior
RFA-18	al_r → ls al_l → ls	Asa do nariz - Lábio superior
RFA-19	al_r → mid al_l → mid	Asa do nariz - Midnasal
RFA-20	al_r → n al_l → n	Asa do nariz - Nasion
RFA-21	al_r → pu_r al_l → pu_l	Asa do nariz - Pupil (Mesmo lado)
RFA-22	al_r → pu_l al_l → pu_r	Asa do nariz - Pupil (Lados diferentes)
RFA-23	al_r → sn al_l → sn	Asa do nariz - Base do nariz
RFA-24	al_r → sto al_l → sto	Asa do nariz - Stomion
RFA-25	al_r → zy_r al_l → zy_l	Asa do nariz - Zygion (Mesmo lado)
RFA-26	al_r → zy_l al_l → zy_r	Asa do nariz - Zygion (Lados diferentes)
RFA-27	ch_r → ch_l ch_l → ch_r	Largura da boca
RFA-28	ch_r → cph_r ch_l → cph_l	Labial Commissure - Crista philtri (Mesmo lado)
RFA-29	ch_r → cph_l ch_l → cph_r	Labial Commissure - Crista philtri (Lados diferentes)
RFA-30	ch_r → ec_r ch_l → ec_l	Labial Commissure - Ectocanthion (Mesmo lado)
RFA-31	ch_r → ec_l ch_l → ec_r	Labial Commissure - Ectocanthion (Lados diferentes)
RFA-32	ch_r → en_r ch_l → en_l	Labial Commissure - Endocanthion (Mesmo lado)
RFA-33	ch_r → en_l ch_l → en_r	Labial Commissure - Endocanthion (Lados diferentes)
RFA-34	ch_r → g ch_l → g	Labial Commissure - Glabella
RFA-35	ch_r → gn ch_l → gn	Labial Commissure - Queixo

Continua na próxima página

Tabela A.1

RFA	Landmarks	Descrição
RFA-36	ch_r → go_r ch_l → go_l	Labial Commissure - Gonion (Mesmo lado)
RFA-37	ch_r → go_l ch_l → go_r	Labial Commissure - Gonion (Lados diferentes)
RFA-38	ch_r → il_r ch_l → il_l	Labial Commissure - Lateral iris (Mesmo lado)
RFA-39	ch_r → il_l ch_l → il_r	Labial Commissure - Lateral iris (Lados diferentes)
RFA-40	ch_r → im_r ch_l → im_l	Labial Commissure - Medial iris (Mesmo lado)
RFA-41	ch_r → im_l ch_l → im_r	Labial Commissure - Medial iris (Lados diferentes)
RFA-42	ch_r → li ch_l → li	Labial Commissure - Lábio inferior
RFA-43	ch_r → ls ch_l → ls	Labial Commissure - Lábio superior
RFA-44	ch_r → mid ch_l → mid	Labial Commissure - Midnasal
RFA-45	ch_r → n ch_l → n	Labial Commissure - Nasion
RFA-46	ch_r → pu_r ch_l → pu_l	Labial Commissure - Pupil (Mesmo lado)
RFA-47	ch_r → pu_l ch_l → pu_r	Labial Commissure - Pupil (Lados diferentes)
RFA-48	ch_r → sn ch_l → sn	Labial Commissure - Base do nariz
RFA-49	ch_r → sto ch_l → sto	Labial Commissure - Stomion
RFA-50	ch_r → zy_r ch_l → zy_l	Labial Commissure - Zygion (Mesmo lado)
RFA-51	ch_r → zy_l ch_l → zy_r	Labial Commissure - Zygion (Lados diferentes)
RFA-52	cph_r → cph_l cph_l → cph_r	Largura da crista philtri
RFA-53	cph_r → ec_r cph_l → ec_l	Crista philtri - Ectocanthion (Mesmo lado)
RFA-54	cph_r → ec_l cph_l → ec_r	Crista philtri - Ectocanthion (Lados diferentes)
RFA-55	cph_r → en_r cph_l → en_l	Crista philtri - Endocanthion (Mesmo lado)
RFA-56	cph_r → en_l cph_l → en_r	Crista philtri - Endocanthion (Lados diferentes)
RFA-57	cph_r → g cph_l → g	Crista philtri - Glabella
RFA-58	cph_r → gn cph_l → gn	Crista philtri - Queixo
RFA-59	cph_r → go_r cph_l → go_l	Crista philtri - Gonion (Mesmo lado)
RFA-60	cph_r → go_l cph_l → go_r	Crista philtri - Gonion (Lados diferentes)
RFA-61	cph_r → il_r cph_l → il_l	Crista philtri - Lateral iris (Mesmo lado)
RFA-62	cph_r → il_l cph_l → il_r	Crista philtri - Lateral iris (Lados diferentes)
RFA-63	cph_r → im_r cph_l → im_l	Crista philtri - Medial iris (Mesmo lado)
RFA-64	cph_r → im_l cph_l → im_r	Crista philtri - Medial iris (Lados diferentes)
RFA-65	cph_r → li cph_l → li	Crista philtri - Lábio inferior
RFA-66	cph_r → ls cph_l → ls	Crista philtri - Lábio superior
RFA-67	cph_r → mid cph_l → mid	Crista philtri - Midnasal
RFA-68	cph_r → n cph_l → n	Crista philtri - Nasion
RFA-69	cph_r → pu_r cph_l → pu_l	Crista philtri - Pupil (Mesmo lado)
RFA-70	cph_r → pu_l cph_l → pu_r	Crista philtri - Pupil (Lados diferentes)
RFA-71	cph_r → sn cph_l → sn	Crista philtri - Base do nariz
RFA-72	cph_r → sto cph_l → sto	Crista philtri - Stomion

Continua na próxima página

Tabela A.1

RFA	Landmarks	Descrição
RFA-73	cph_r → zy_r cph_l → zy_l	Crista philtri - Zygion (Mesmo lado)
RFA-74	cph_r → zy_l cph_l → zy_r	Crista philtri - Zygion (Lados diferentes)
RFA-75	ec_r → ec_l ec_l → ec_r	Largura da ectocanthion
RFA-76	ec_r → en_r ec_l → en_l	Largura do olho
RFA-77	ec_r → en_l ec_l → en_r	Ectocanthion - Endocanthion (Lados diferentes)
RFA-78	ec_r → g ec_l → g	Ectocanthion - Glabella
RFA-79	ec_r → gn ec_l → gn	Ectocanthion - Queixo
RFA-80	ec_r → go_r ec_l → go_l	Ectocanthion - Gonion (Mesmo lado)
RFA-81	ec_r → go_l ec_l → go_r	Ectocanthion - Gonion (Lados diferentes)
RFA-82	ec_r → il_r ec_l → il_l	Ectocanthion - Lateral iris (Mesmo lado)
RFA-83	ec_r → il_l ec_l → il_r	Ectocanthion - Lateral iris (Lados diferentes)
RFA-84	ec_r → im_r ec_l → im_l	Ectocanthion - Medial iris (Mesmo lado)
RFA-85	ec_r → im_l ec_l → im_r	Ectocanthion - Medial iris (Lados diferentes)
RFA-86	ec_r → li ec_l → li	Ectocanthion - Lábio inferior
RFA-87	ec_r → ls ec_l → ls	Ectocanthion - Lábio superior
RFA-88	ec_r → mid ec_l → mid	Ectocanthion - Midnasal
RFA-89	ec_r → n ec_l → n	Ectocanthion - Nasion
RFA-90	ec_r → pu_r ec_l → pu_l	Ectocanthion - Pupil (Mesmo lado)
RFA-91	ec_r → pu_l ec_l → pu_r	Ectocanthion - Pupil (Lados diferentes)
RFA-92	ec_r → sn ec_l → sn	Ectocanthion - Base do nariz
RFA-93	ec_r → sto ec_l → sto	Ectocanthion - Stomion
RFA-94	ec_r → zy_r ec_l → zy_l	Ectocanthion - Zygion (Mesmo lado)
RFA-95	ec_r → zy_l ec_l → zy_r	Ectocanthion - Zygion (Lados diferentes)
RFA-96	en_r → en_l en_l → en_r	Largura inter-canthion
RFA-97	en_r → g en_l → g	Endocanthion - Glabella
RFA-98	en_r → gn en_l → gn	Endocanthion - Queixo
RFA-99	en_r → go_r en_l → go_l	Endocanthion - Gonion (Mesmo lado)
RFA-100	en_r → go_l en_l → go_r	Endocanthion - Gonion (Lados diferentes)
RFA-101	en_r → il_r en_l → il_l	Endocanthion - Lateral iris (Mesmo lado)
RFA-102	en_r → il_l en_l → il_r	Endocanthion - Lateral iris (Lados diferentes)
RFA-103	en_r → im_r en_l → im_l	Endocanthion - Medial iris (Mesmo lado)
RFA-104	en_r → im_l en_l → im_r	Endocanthion - Medial iris (Lados diferentes)
RFA-105	en_r → li en_l → li	Endocanthion - Lábio inferior
RFA-106	en_r → ls en_l → ls	Endocanthion - Lábio superior
RFA-107	en_r → mid en_l → mid	Endocanthion - Midnasal
RFA-108	en_r → n en_l → n	Endocanthion - Nasion
RFA-109	en_r → pu_r en_l → pu_l	Endocanthion - Pupil (Mesmo lado)

Continua na próxima página

Tabela A.1

RFA	Landmarks	Descrição
RFA-110	en_r → pu_l en_l → pu_r	Endocanthion - Pupil (Lados diferentes)
RFA-111	en_r → sn en_l → sn	Endocanthion - Base do nariz
RFA-112	en_r → sto en_l → sto	Endocanthion - Stomion
RFA-113	en_r → zy_r en_l → zy_l	Endocanthion - Zygion (Mesmo lado)
RFA-114	en_r → zy_l en_l → zy_r	Endocanthion - Zygion (Lados diferentes)
RFA-115	g → gn	Height of the face
RFA-116	g → go_r g → go_l	Glabella - Gonion (Mesmo lado)
RFA-117	g → il_r g → il_l	Glabella - Gonion (Lados diferentes)
RFA-118	g → im_r g → im_l	Glabella - Medial iris
RFA-119	g → li	Glabella - Lábio superior
RFA-120	g → ls	Glabella - Lábio inferior
RFA-121	g → mid	Glabella Midnasal
RFA-122	g → n	Glabella - Nasion
RFA-123	g → pu_r g → pu_l	Glabella - Pupil
RFA-124	g → sn	Glabella - Base do nariz
RFA-125	g → sto	Glabella - Stomion
RFA-126	g → zy_r g → zy_l	Glabella - Zygion
RFA-127	gn → go_r gn → go_l	Queixo - Gonion
RFA-128	gn → il_r gn → il_l	Queixo - Lateral iris
RFA-129	gn → im_r gn → im_l	Queixo - Medial iris
RFA-130	gn → li	Queixo - Lábio inferior
RFA-131	gn → ls	Queixo - Lábio superior
RFA-132	gn → mid	Queixo - Midnasal
RFA-133	gn → n	Queixo - Nasion
RFA-134	gn → pu_r gn → pu_l	Queixo - Pupil
RFA-135	gn → sn	Queixo - Base do nariz
RFA-136	gn → sto	Queixo - Stomion
RFA-137	gn → zy_r gn → zy_l	Queixo - Zygion
RFA-138	go_r → go_l go_l → go_r	Largura inter-gonion
RFA-139	go_r → il_r go_l → il_l	Gonion - Lateral iris (Mesmo lado)
RFA-140	go_r → il_l go_l → il_r	Gonion - Lateral iris (Lados diferentes)
RFA-141	go_r → im_r go_l → im_l	Gonion - Medial iris (Mesmo lado)
RFA-142	go_r → im_l go_l → im_r	Gonion - Medial iris (Lados diferentes)
RFA-143	go_r → li go_l → li	Gonion - Lábio inferior
RFA-144	go_r → ls go_l → ls	Gonion - Lábio superior
RFA-145	go_r → mid go_l → mid	Gonion - Midnasal
RFA-146	go_r → n go_l → n	Gonion - Nasion

Continua na próxima página

Tabela A.1

RFA	Landmarks	Descrição
RFA-147	go_r → pu_r go_l → pu_l	Gonion - Pupil (Mesmo lado)
RFA-148	go_r → pu_l go_l → pu_r	Gonion - Pupil (Lados diferentes)
RFA-149	go_r → sn go_l → sn	Gonion - Base do nariz
RFA-150	go_r → sto go_l → sto	Gonion - Stomion
RFA-151	go_r → zy_r go_l → zy_l	Gonion - Zygion (Mesmo lado)
RFA-152	go_r → zy_l go_l → zy_r	Gonion - Zygion (Lados diferentes)
RFA-153	il_r → il_l il_l → il_r	Largura máxima da íris
RFA-154	il_r → im_r il_l → im_l	Diametro da íris
RFA-155	il_r → im_l il_l → im_r	Lateral iris - Medial iris (Lados diferentes)
RFA-156	il_r → li il_l → li	Lateral iris - Lábio superior
RFA-157	il_r → ls il_l → ls	Lateral iris - Lábio superior
RFA-158	il_r → mid il_l → mid	Lateral iris - Midnasal
RFA-159	il_r → n il_l → n	Lateral iris - Nasion
RFA-160	il_r → pu_r il_l → pu_l	Lateral iris - Pupil (Mesmo lado)
RFA-161	il_r → pu_l il_l → pu_r	Lateral iris - Pupil (Lados diferentes)
RFA-162	il_r → sn il_l → sn	Lateral iris - Base do nariz
RFA-163	il_r → sto il_l → sto	Lateral iris - Stomion
RFA-164	il_r → zy_r il_l → zy_l	Lateral iris - Zygion (Mesmo lado)
RFA-165	il_r → zy_l il_l → zy_r	Lateral iris - Zygion (Lados diferentes)
RFA-166	im_r → im_l im_l → im_r	Largura mínima da íris
RFA-167	im_r → li im_l → li	Medial iris - Lábio inferior
RFA-168	im_r → ls im_l → ls	Medial iris - Lábio superior
RFA-169	im_r → mid im_l → mid	Medial iris - Midnasal
RFA-170	im_r → n im_l → n	Medial iris - Nasion
RFA-171	im_r → pu_r im_l → pu_l	Medial iris - Pupil (Mesmo lado)
RFA-172	im_r → pu_l im_l → pu_r	Medial iris - Pupil (Lados diferentes)
RFA-173	im_r → sn im_l → sn	Medial iris - Base do nariz
RFA-174	im_r → sto im_l → sto	Medial iris - Stomion
RFA-175	im_r → zy_r im_l → zy_l	Medial iris - Zygion (Mesmo lado)
RFA-176	im_r → zy_l im_l → zy_r	Medial iris - Zygion (Lados diferentes)
RFA-177	li → ls	Comprimento dos lábios
RFA-178	li → mid	Lábio inferior - Midnasal
RFA-179	li → n	Lábio inferior - Nasion
RFA-180	li → pu_r li → pu_l	Lábio inferior - Pupil
RFA-181	li → sn	Lábio inferior - Base do nariz
RFA-182	li → sto	Lábio inferior - Stomion
RFA-183	li → zy_r li → zy_l	Lábio inferior - Zygion

Continua na próxima página

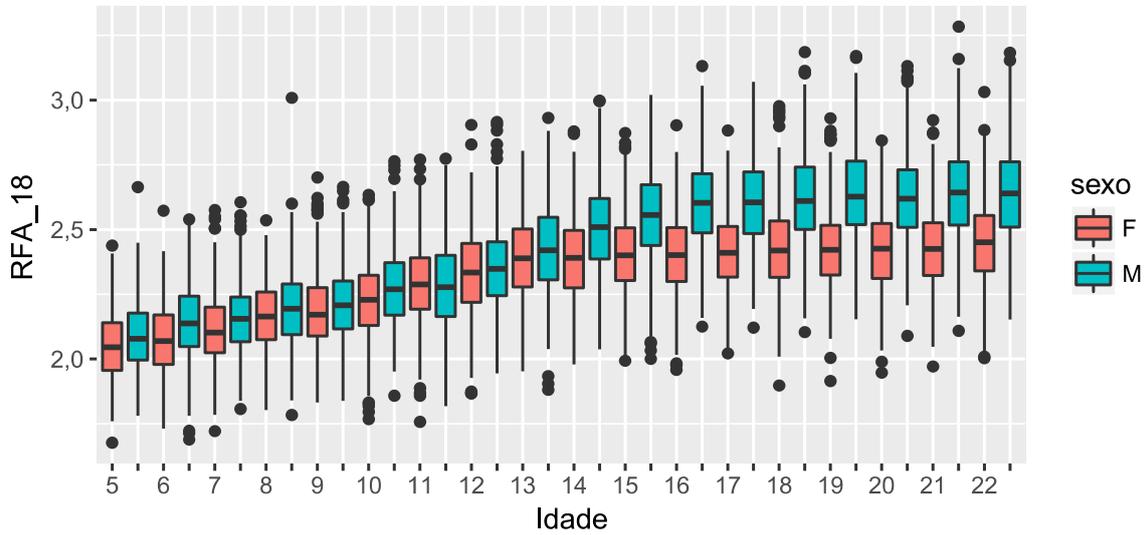
Tabela A.1

RFA	Landmarks	Descrição
RFA-184	ls → mid	Lábio superior - Midnasal
RFA-185	ls → n	Lábio superior - Nasion
RFA-186	ls → pu_r ls → pu_l	Lábio superior - Pupil
RFA-187	ls → sn	Lábio superior - Base do nariz
RFA-188	ls → sto	Lábio superior - Stomion
RFA-189	ls → zy_r ls → zy_l	Lábio superior - Zygion
RFA-190	mid → n	Midnasal - Nasion
RFA-191	mid → pu_r mid → pu_l	Midnasal - Pupil
RFA-192	mid → sn	Midnasal - Base do nariz
RFA-193	mid → sto	Midnasal - Stomion
RFA-194	mid → zy_r mid → zy_l	Midnasal - Zygion
RFA-195	n → pu_r n → pu_l	Nasion - Pupil
RFA-196	n → sn	Comprimento do nariz
RFA-197	n → sto	Nasion - Stomion
RFA-198	n → zy_r n → zy_l	Nasion - Zygion
RFA-199	pu_r → pu_l pu_l → pu_r	Largura inter-pupil
RFA-200	pu_r → sn pu_l → sn	Pupil - Base do nariz
RFA-201	pu_r → sto pu_l → sto	Pupil - Stomion
RFA-202	pu_r → zy_r pu_l → zy_l	Pupil - Zygion (Mesmo lado)
RFA-203	pu_r → zy_l pu_l → zy_r	Pupil - Zygion (Lados diferentes)
RFA-204	sn → sto	Base do nariz - Stomion
RFA-205	sn → zy_r sn → zy_l	Base do nariz - Zygion
RFA-206	sto → zy_r sto → zy_l	Stomion - Zygion
RFA-207	zy_r → zy_l zy_l → zy_r	Largura da face

APÊNDICE B. BOXPLOTS RFAS

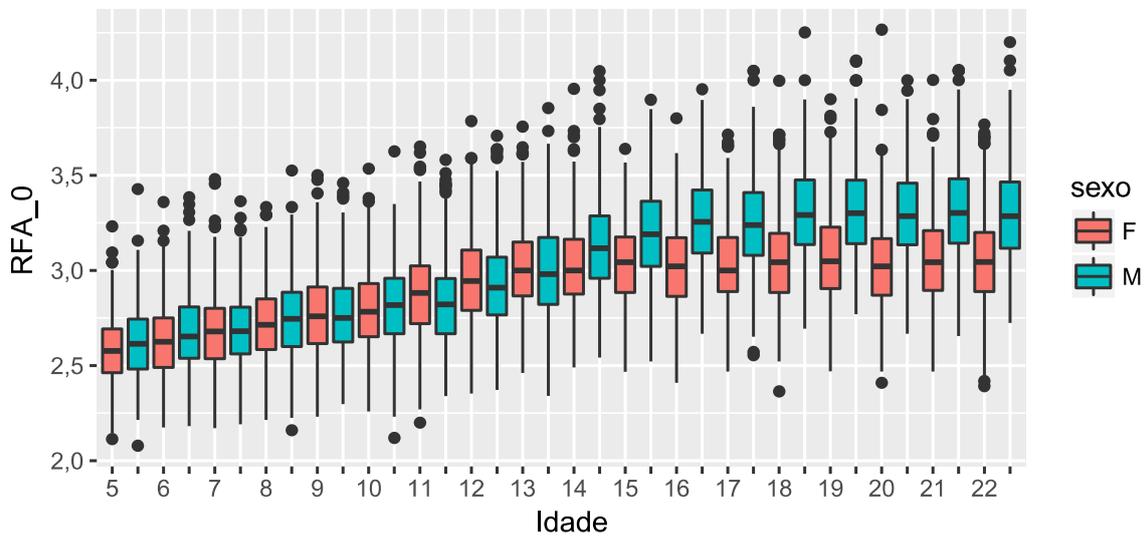
Distribuições da RFA_18 por Sexo e Idade

idades de 5 até 22 anos



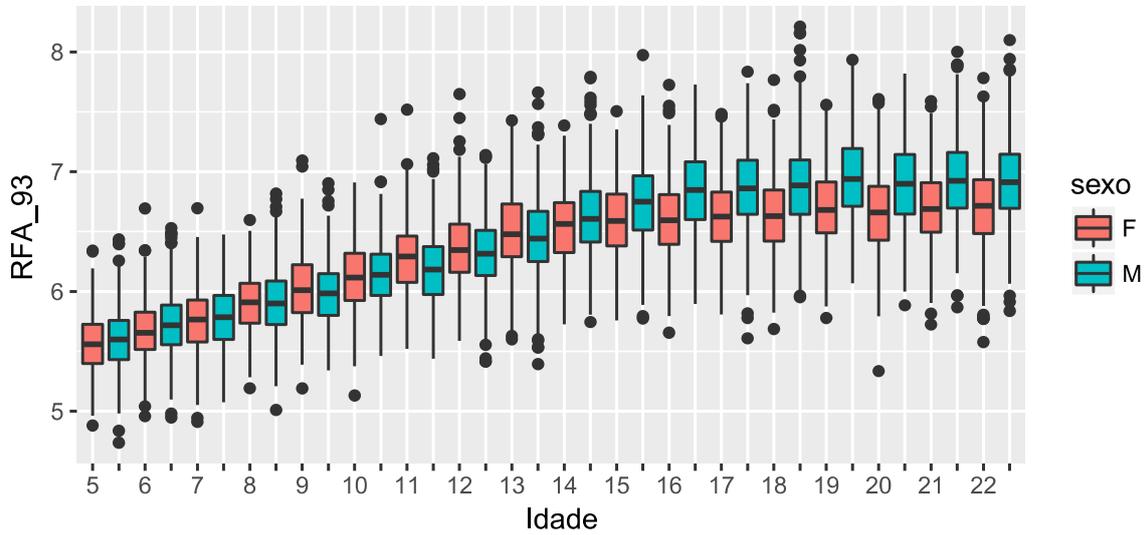
Distribuições da RFA_0 por Sexo e Idade

idades de 5 até 22 anos



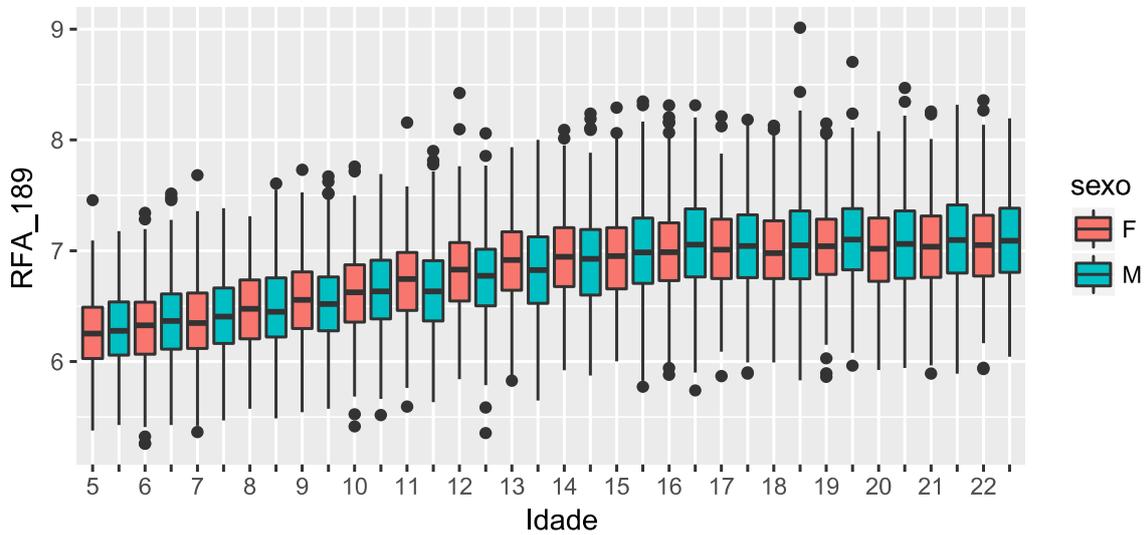
Distribuições da RFA_93 por Sexo e Idade

idades de 5 até 22 anos



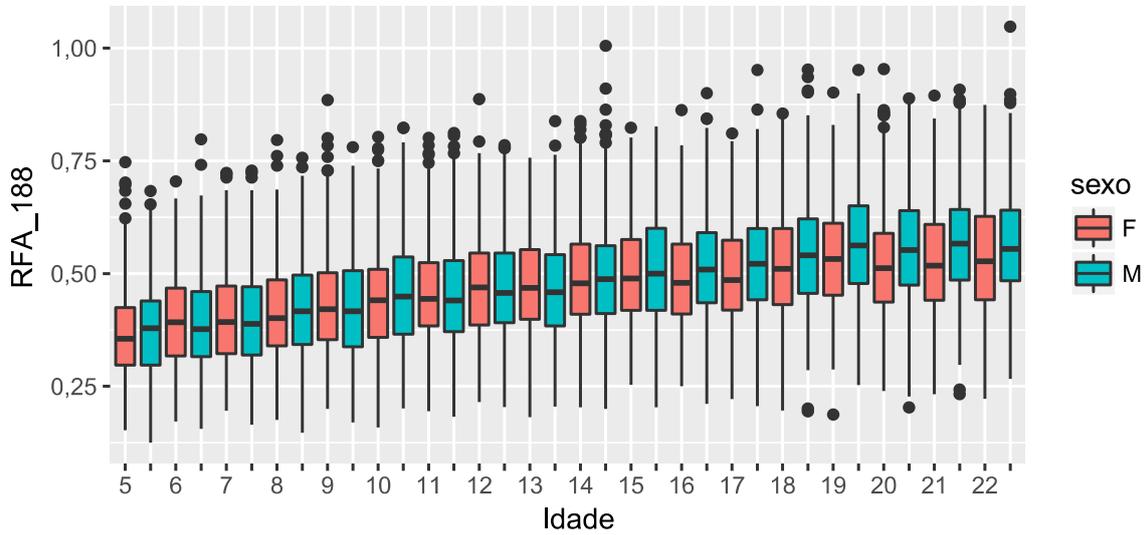
Distribuições da RFA_189 por Sexo e Idade

idades de 5 até 22 anos



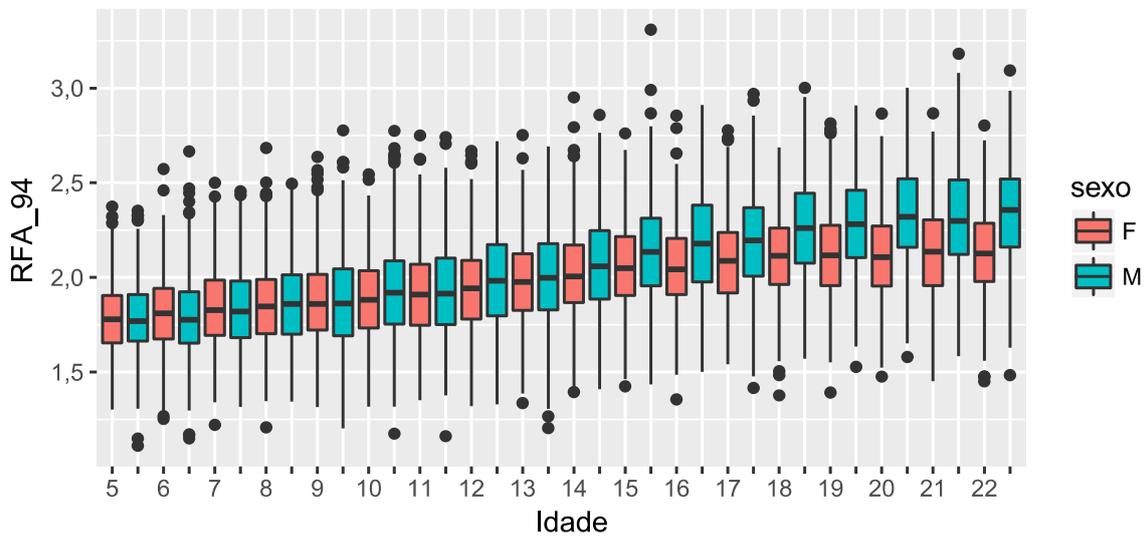
Distribuições da RFA_188 por Sexo e Idade

idades de 5 até 22 anos



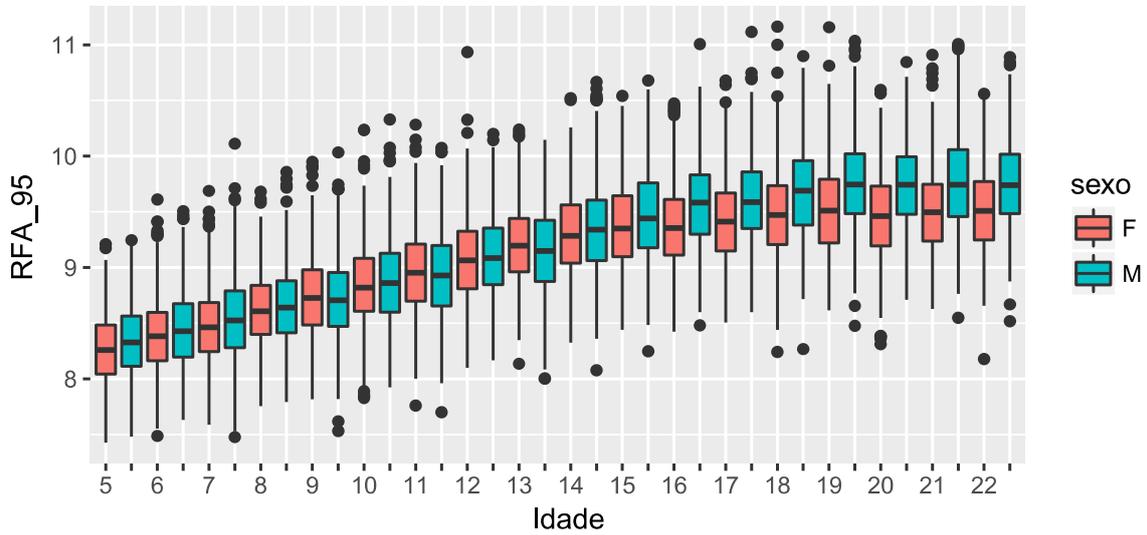
Distribuições da RFA_94 por Sexo e Idade

idades de 5 até 22 anos



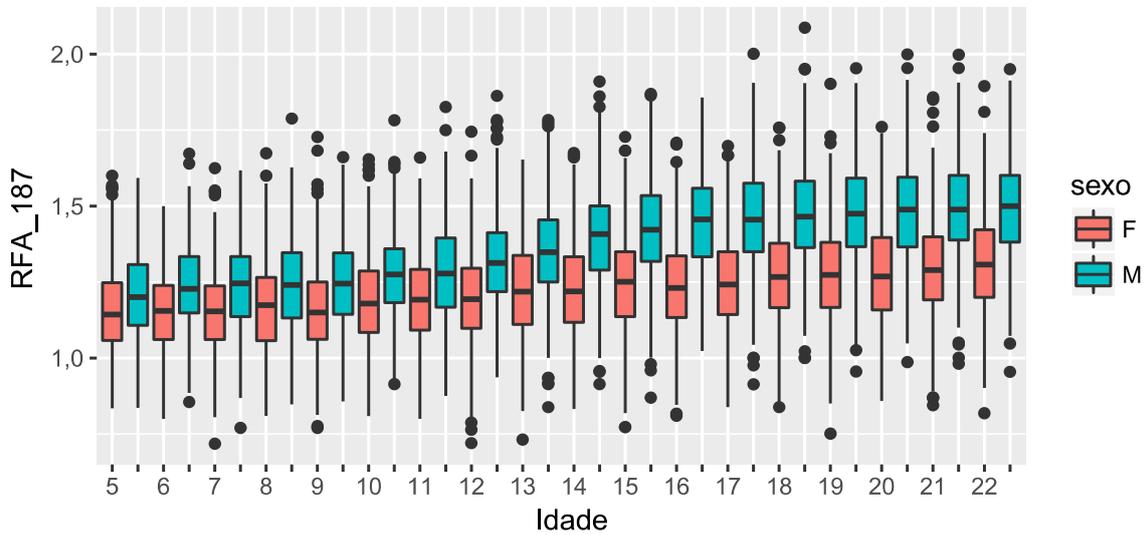
Distribuições da RFA_95 por Sexo e Idade

idades de 5 até 22 anos



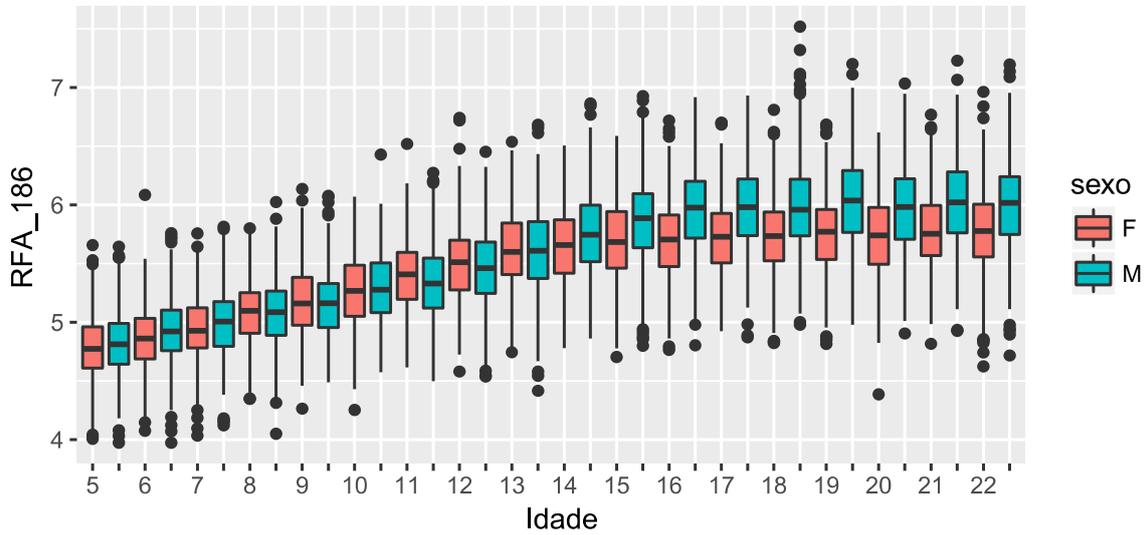
Distribuições da RFA_187 por Sexo e Idade

idades de 5 até 22 anos



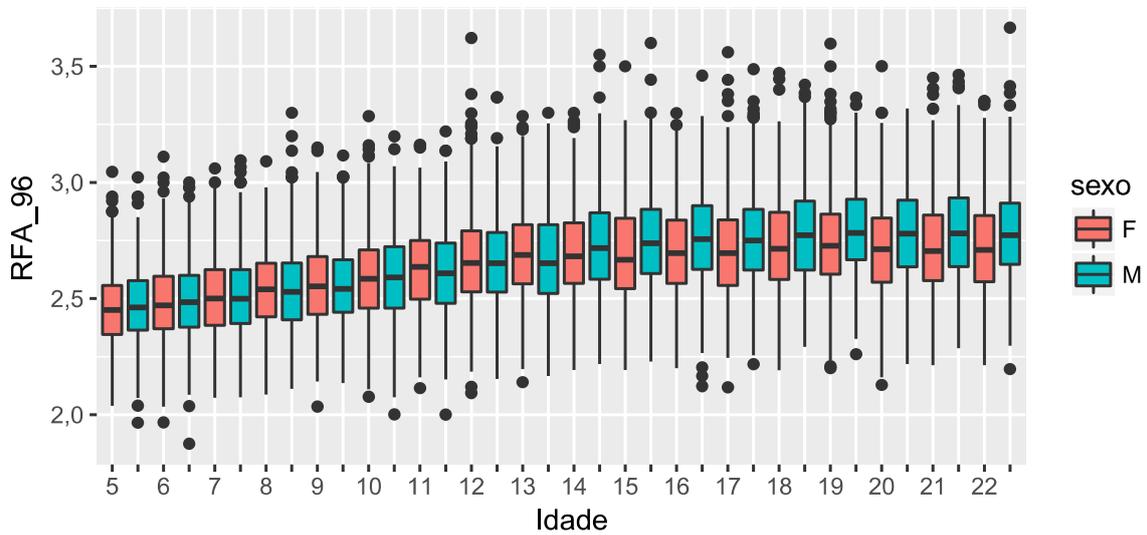
Distribuições da RFA_186 por Sexo e Idade

idades de 5 até 22 anos



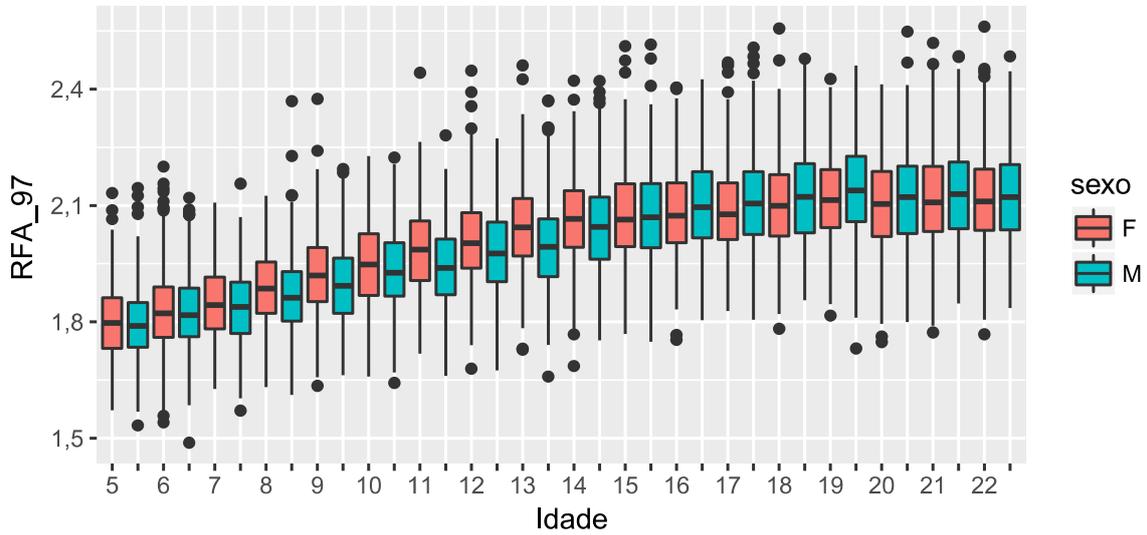
Distribuições da RFA_96 por Sexo e Idade

idades de 5 até 22 anos



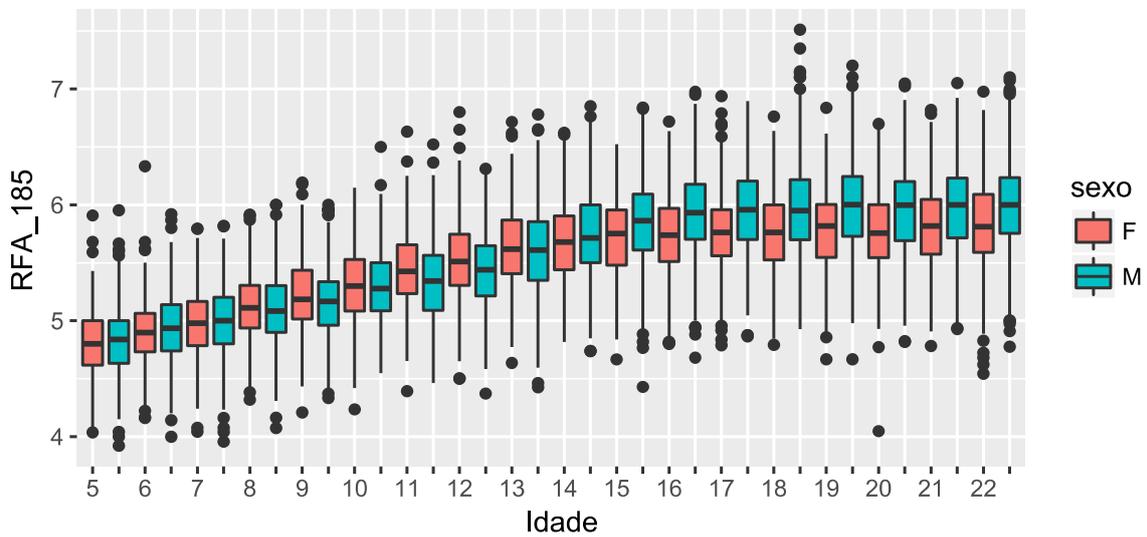
Distribuições da RFA_97 por Sexo e Idade

idades de 5 até 22 anos



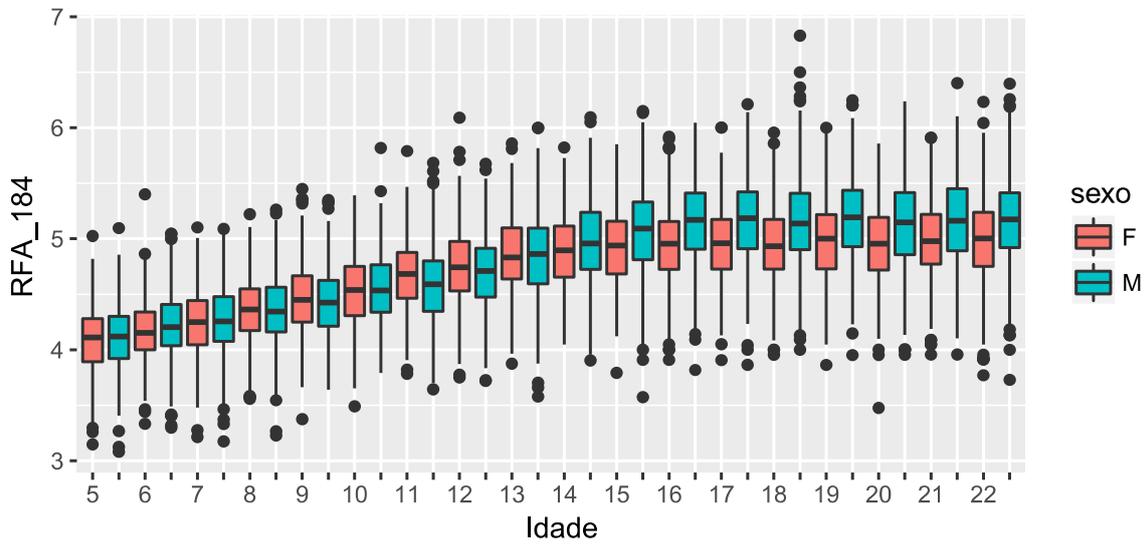
Distribuições da RFA_185 por Sexo e Idade

idades de 5 até 22 anos



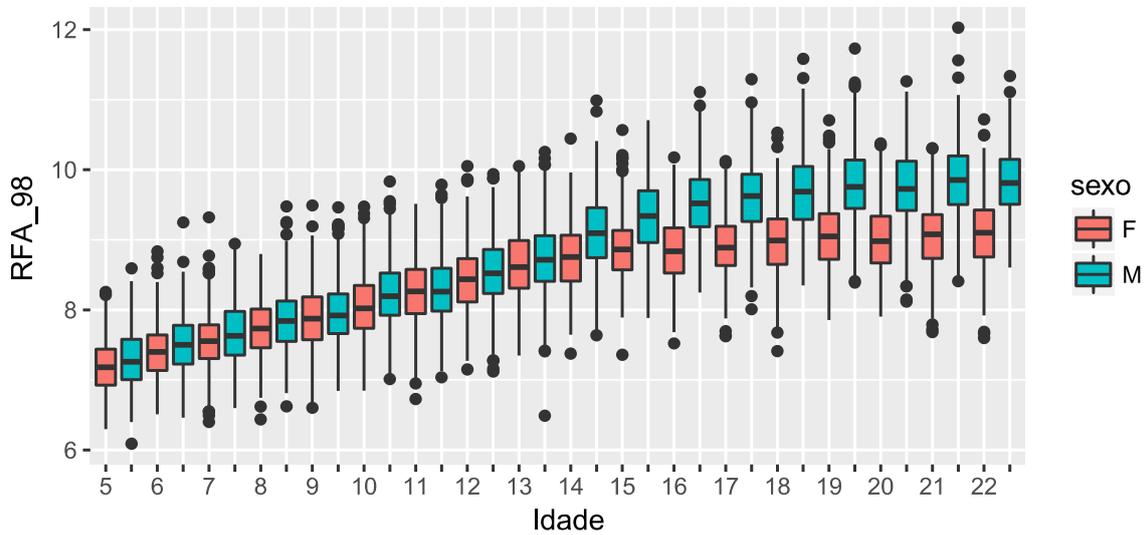
Distribuições da RFA_184 por Sexo e Idade

idades de 5 até 22 anos



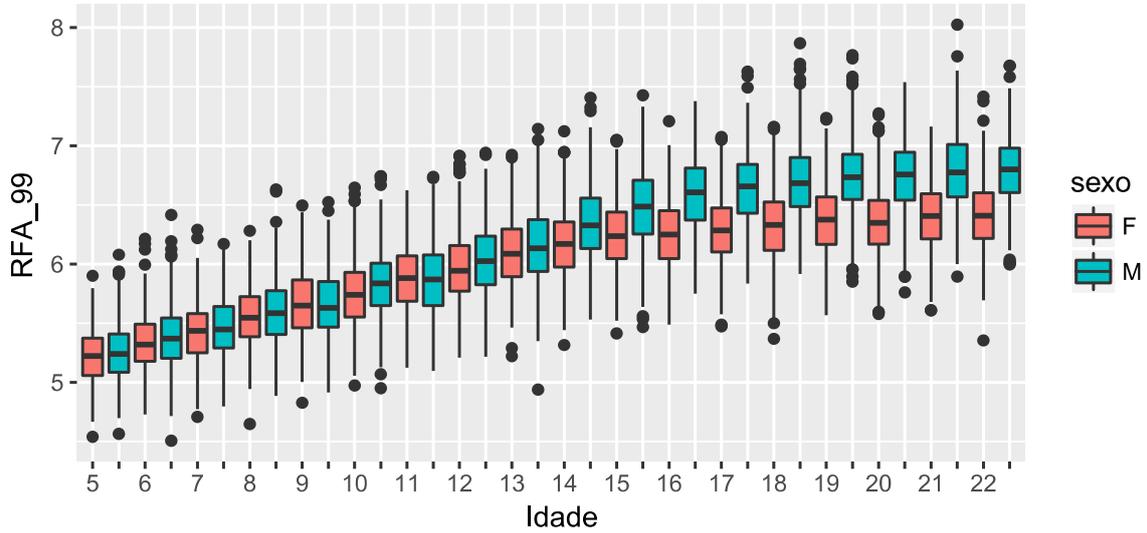
Distribuições da RFA_98 por Sexo e Idade

idades de 5 até 22 anos



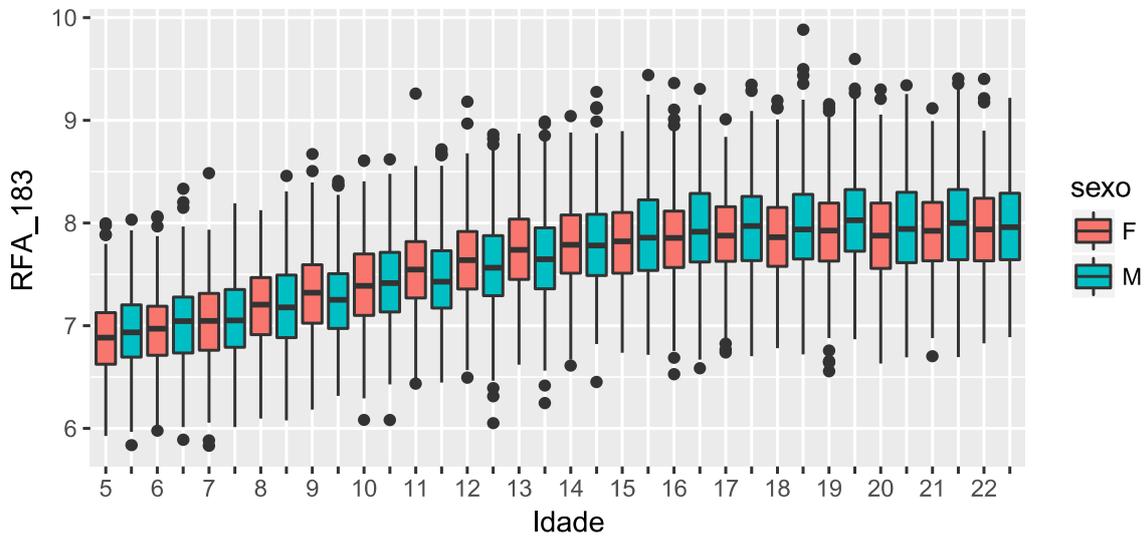
Distribuições da RFA_99 por Sexo e Idade

idades de 5 até 22 anos



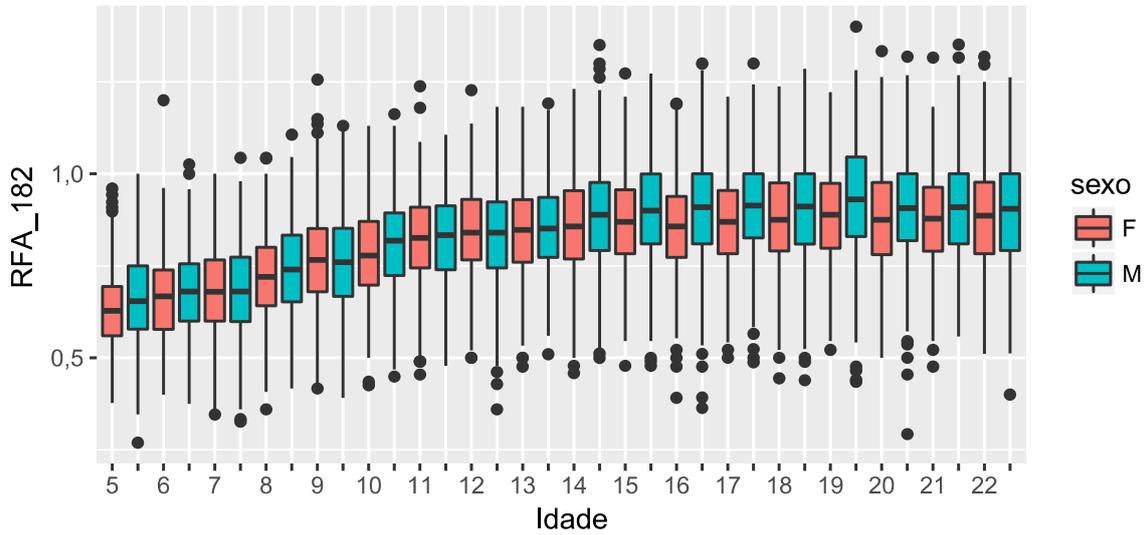
Distribuições da RFA_183 por Sexo e Idade

idades de 5 até 22 anos



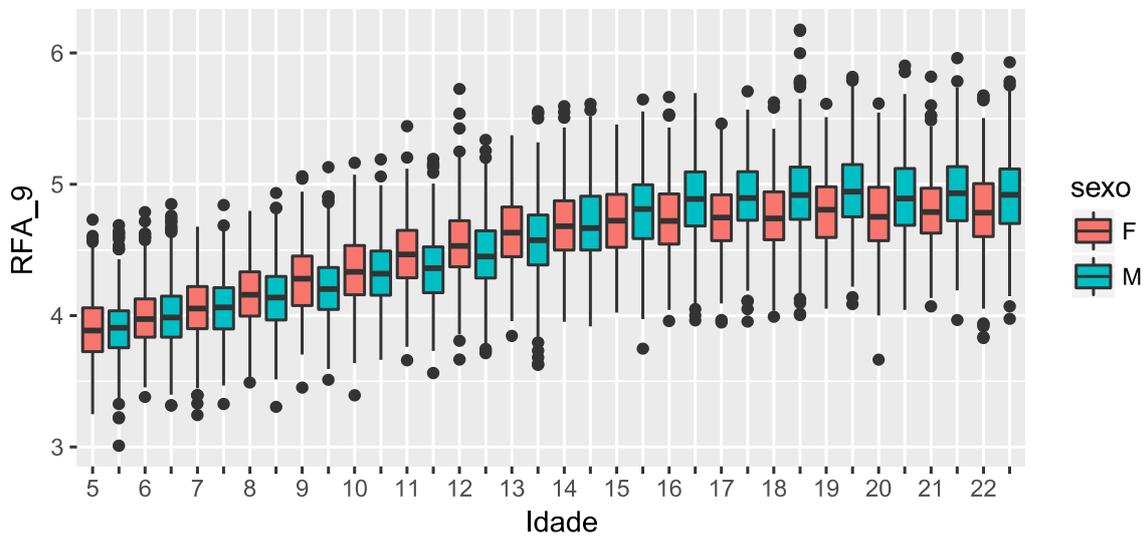
Distribuições da RFA_182 por Sexo e Idade

idades de 5 até 22 anos



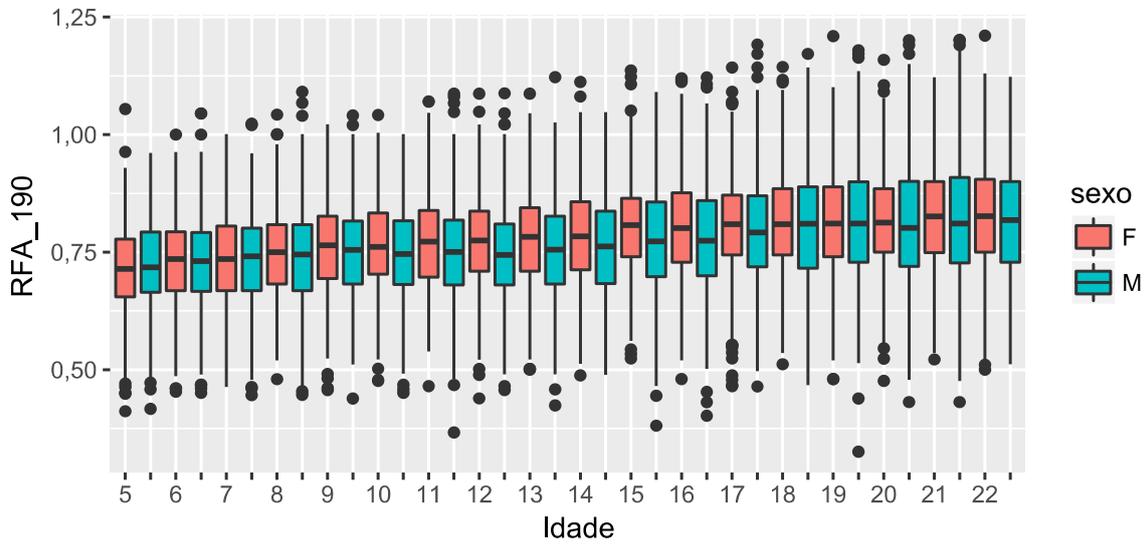
Distribuições da RFA_9 por Sexo e Idade

idades de 5 até 22 anos



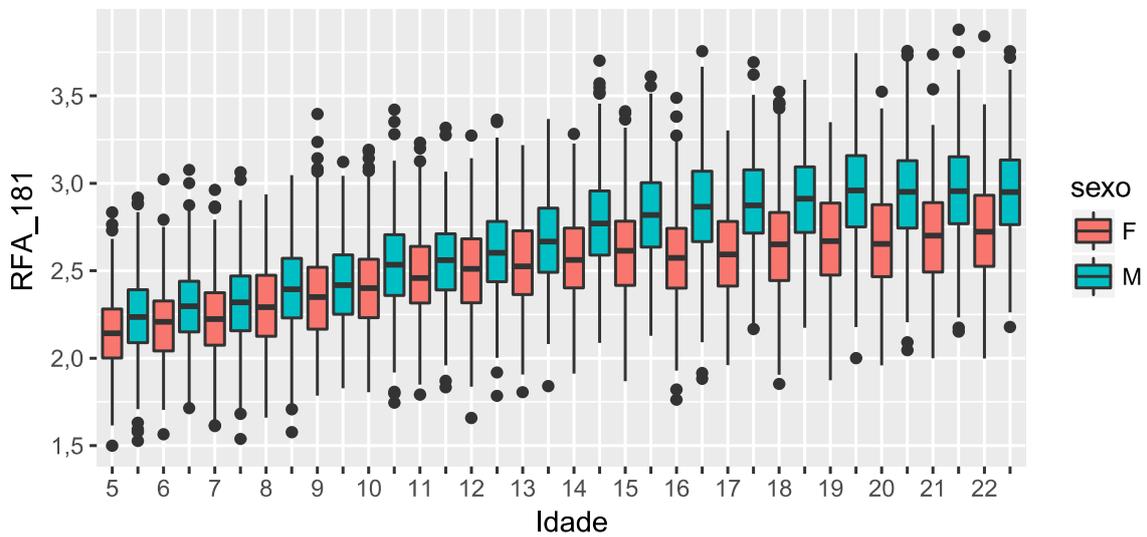
Distribuições da RFA_190 por Sexo e Idade

idades de 5 até 22 anos



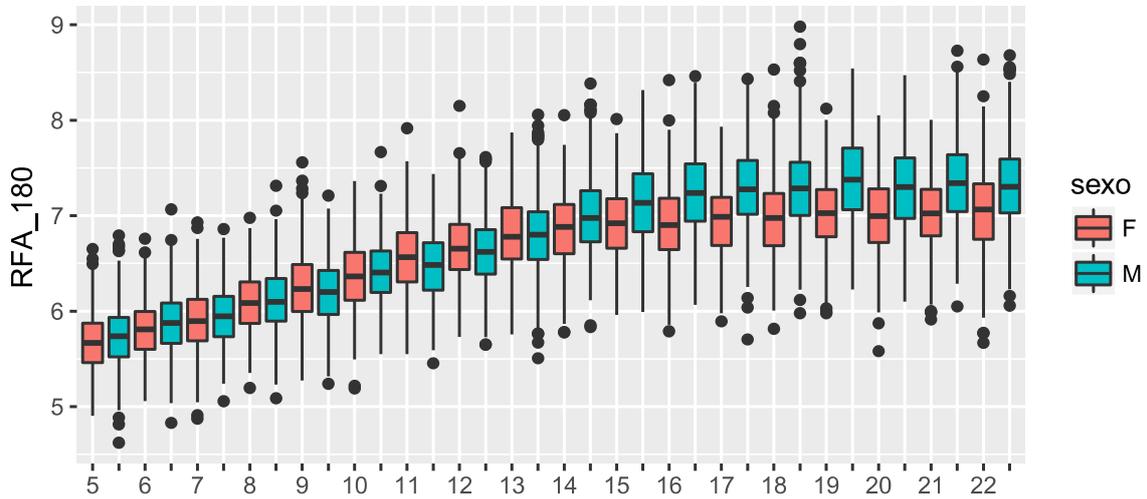
Distribuições da RFA_181 por Sexo e Idade

idades de 5 até 22 anos



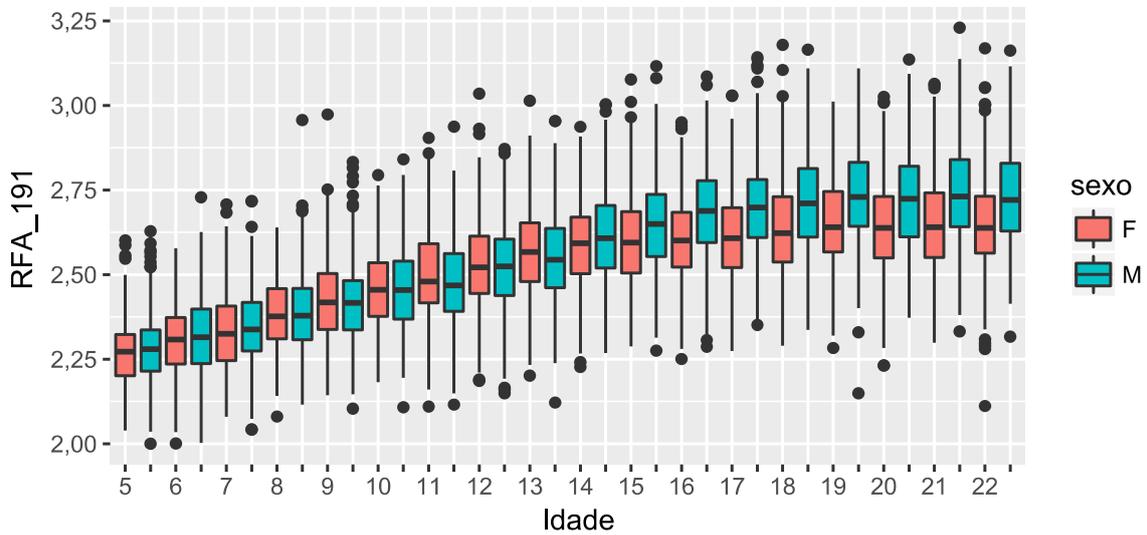
Distribuições da RFA_180 por Sexo e Idade

idades de 5 até 22 anos



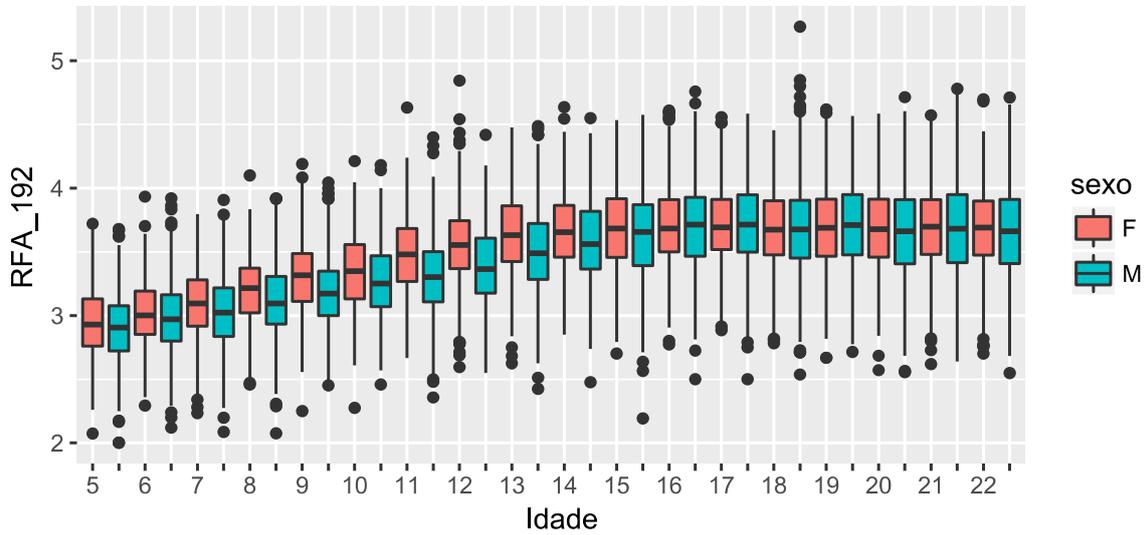
Distribuições da RFA_191 por Sexo e Idade

idades de 5 até 22 anos



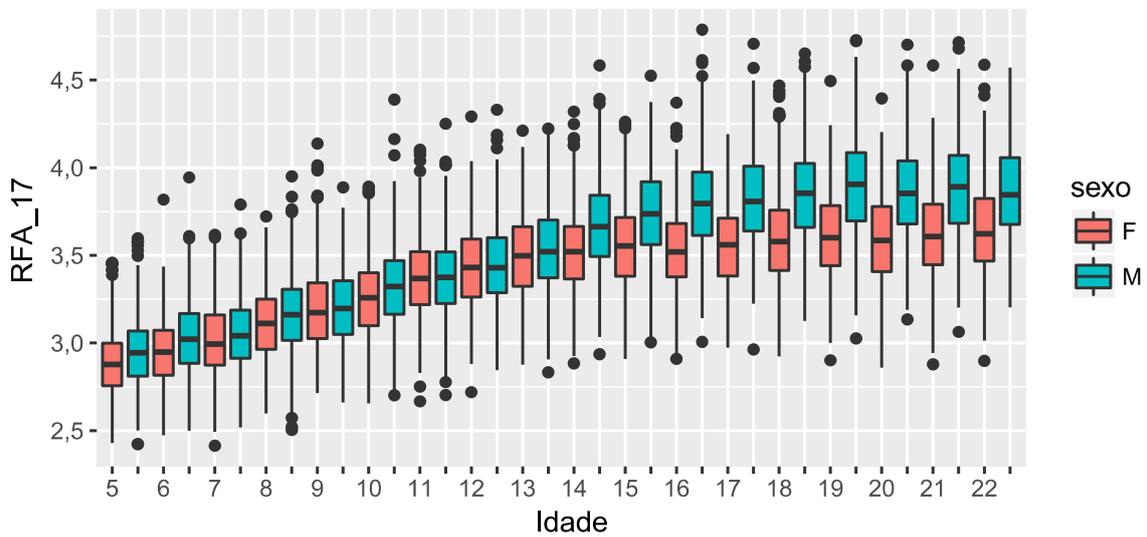
Distribuições da RFA_192 por Sexo e Idade

idades de 5 até 22 anos



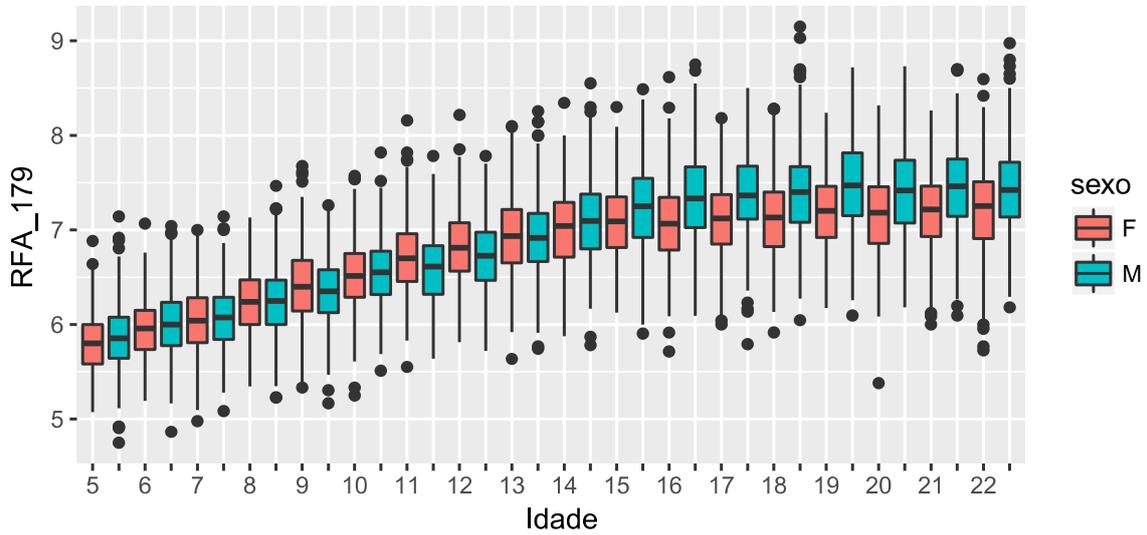
Distribuições da RFA_17 por Sexo e Idade

idades de 5 até 22 anos



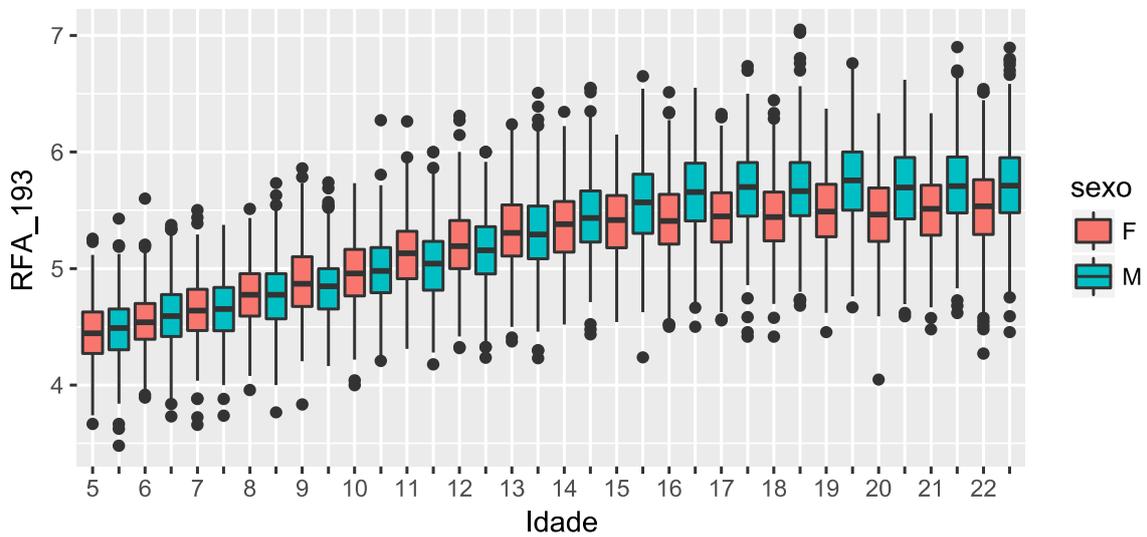
Distribuições da RFA_179 por Sexo e Idade

idades de 5 até 22 anos



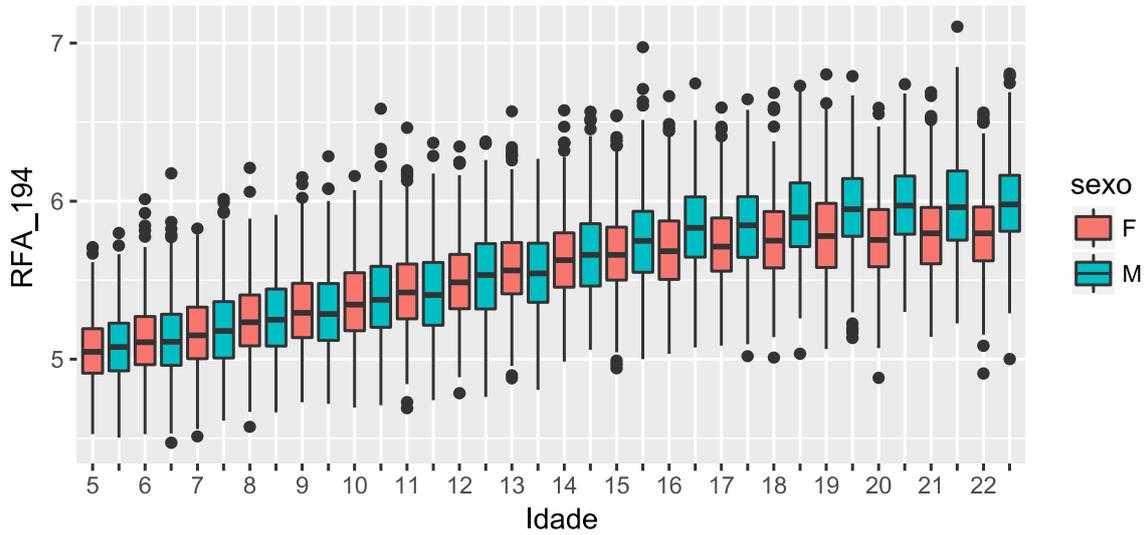
Distribuições da RFA_193 por Sexo e Idade

idades de 5 até 22 anos



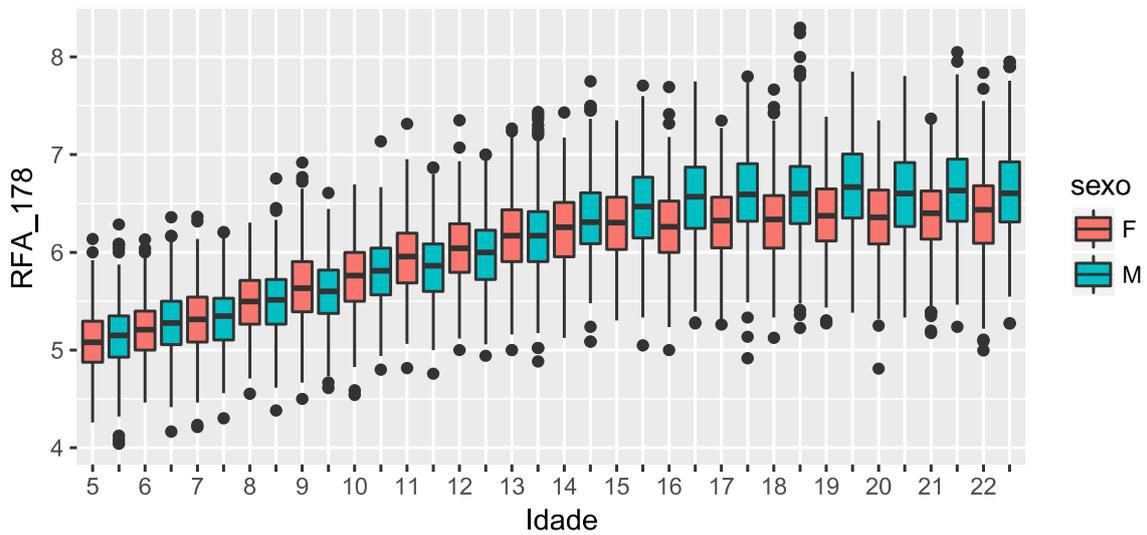
Distribuições da RFA_194 por Sexo e Idade

idades de 5 até 22 anos



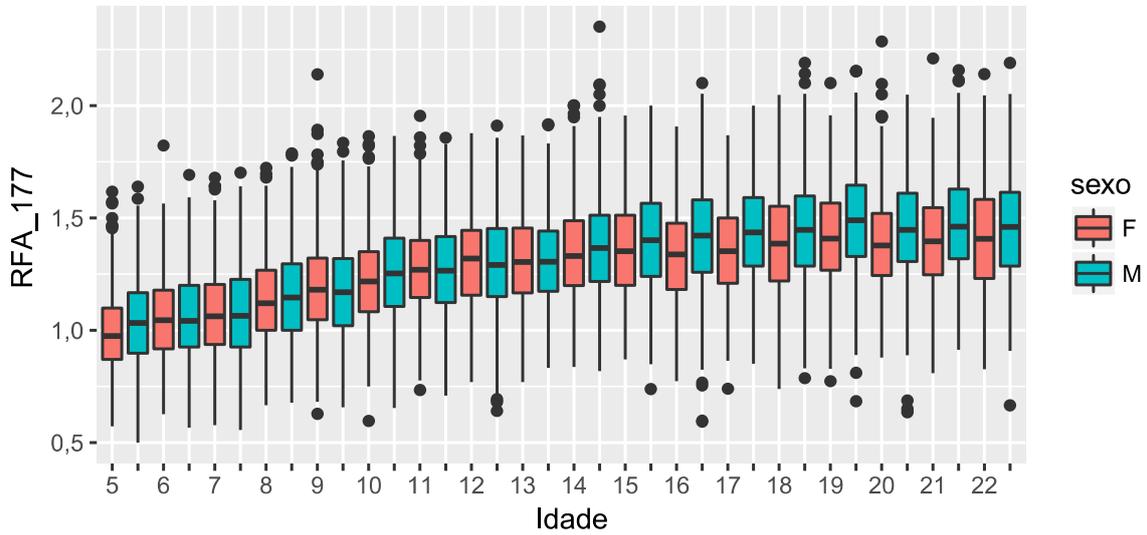
Distribuições da RFA_178 por Sexo e Idade

idades de 5 até 22 anos



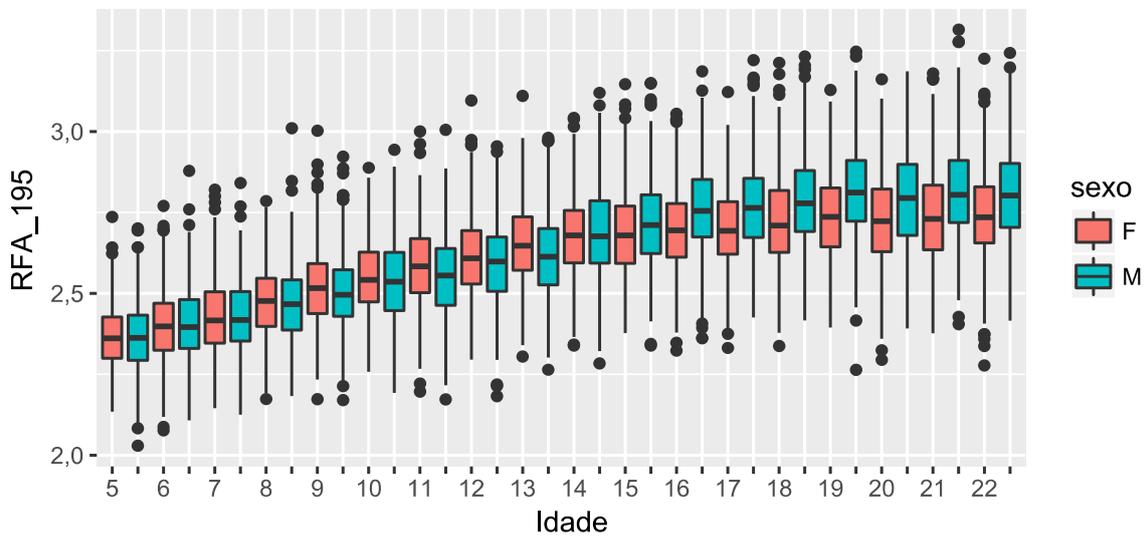
Distribuições da RFA_177 por Sexo e Idade

idades de 5 até 22 anos



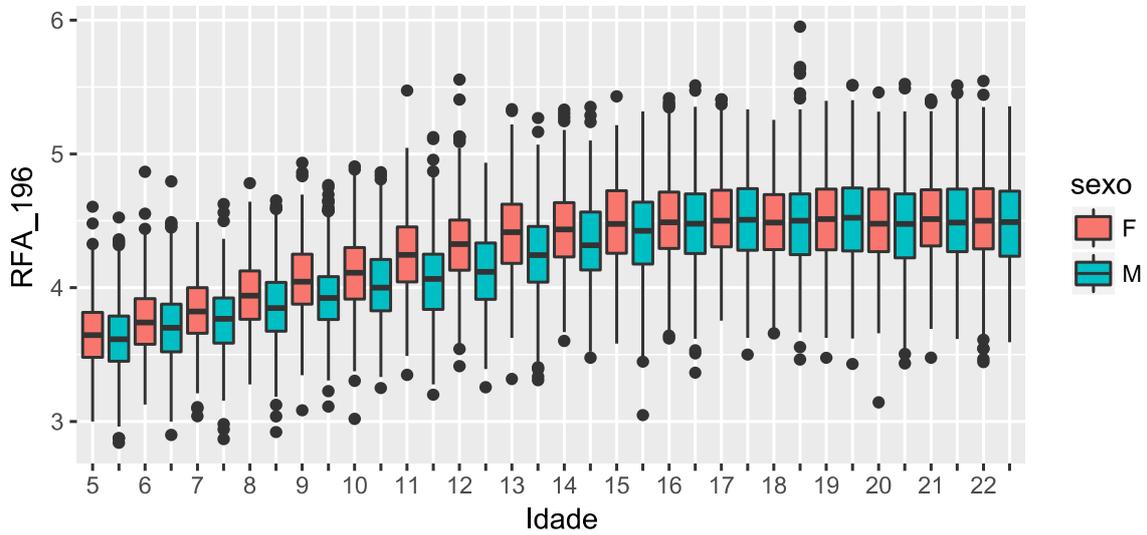
Distribuições da RFA_195 por Sexo e Idade

idades de 5 até 22 anos



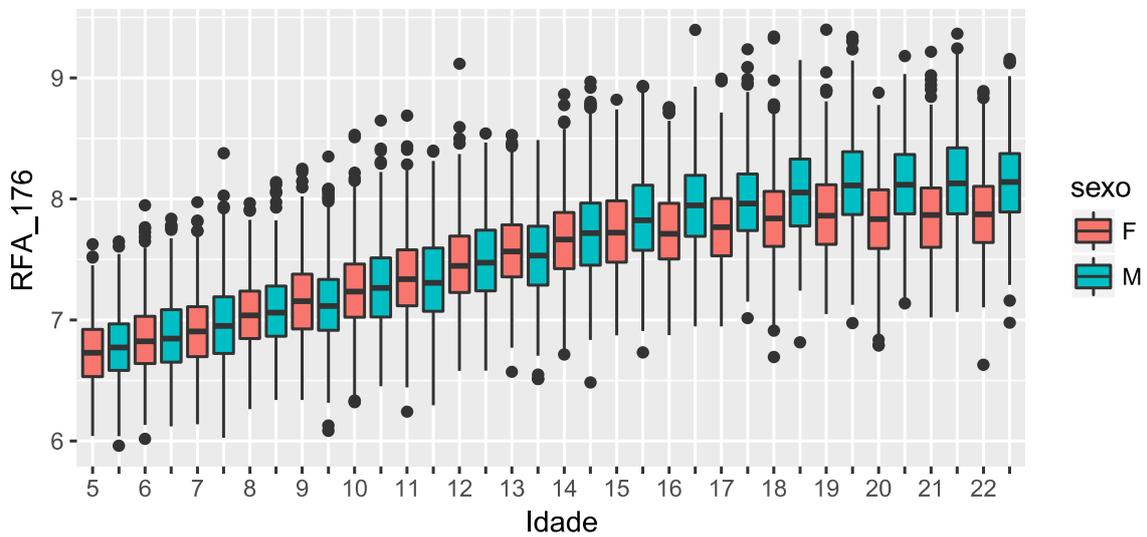
Distribuições da RFA_196 por Sexo e Idade

idades de 5 até 22 anos



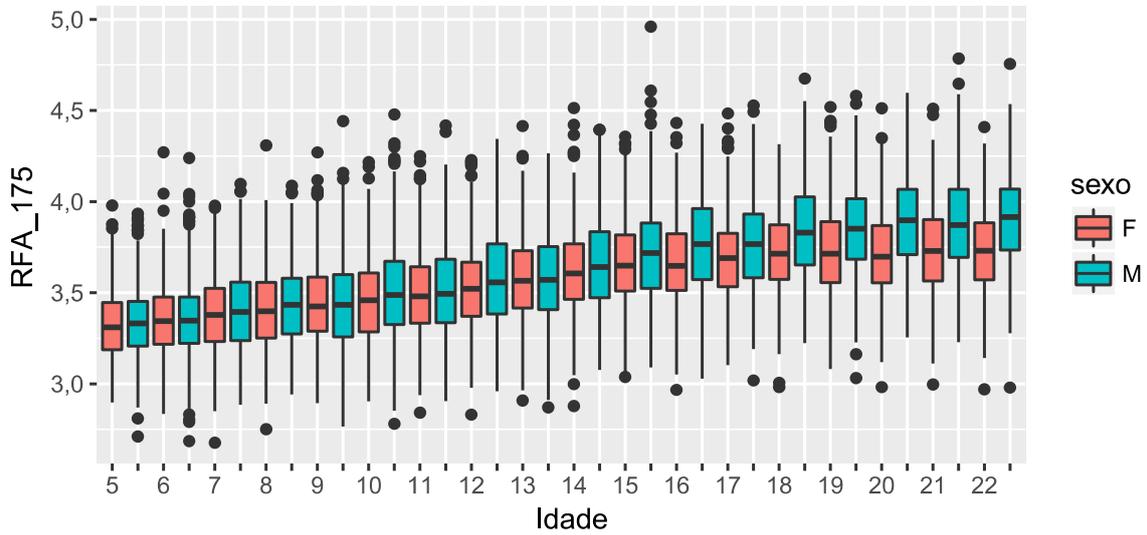
Distribuições da RFA_176 por Sexo e Idade

idades de 5 até 22 anos



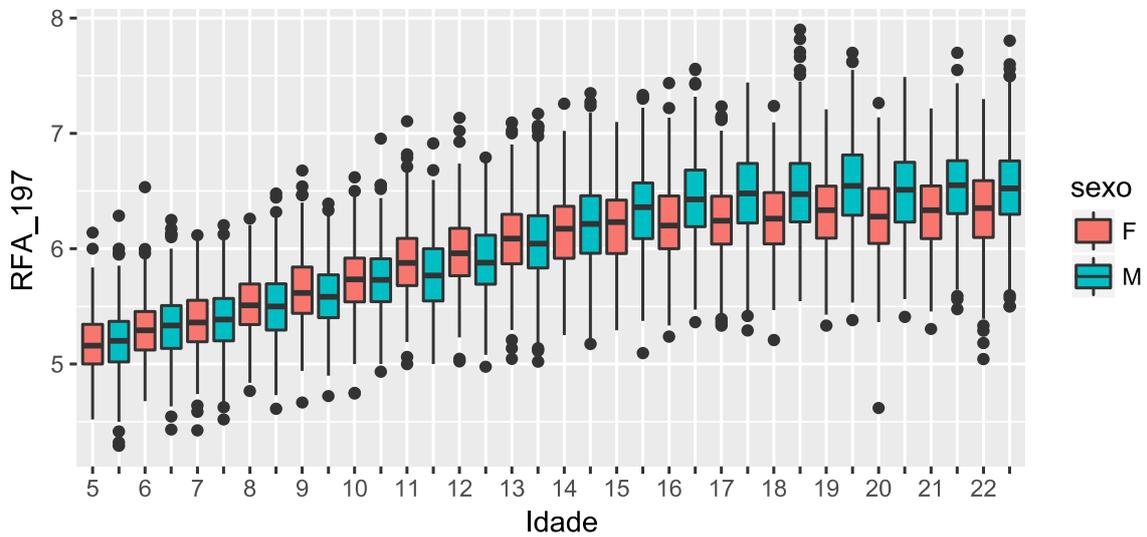
Distribuições da RFA_175 por Sexo e Idade

idades de 5 até 22 anos



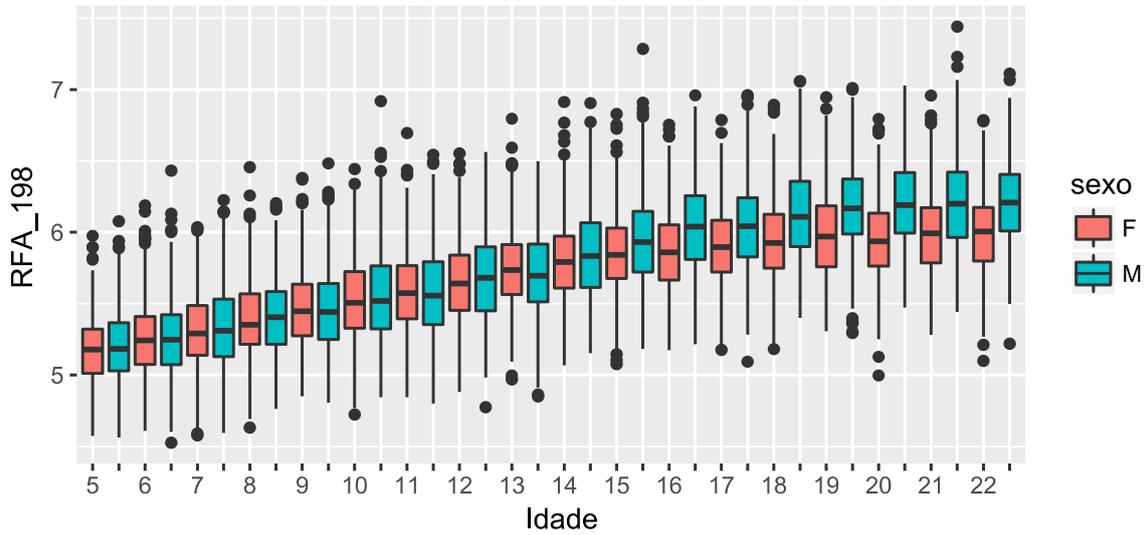
Distribuições da RFA_197 por Sexo e Idade

idades de 5 até 22 anos



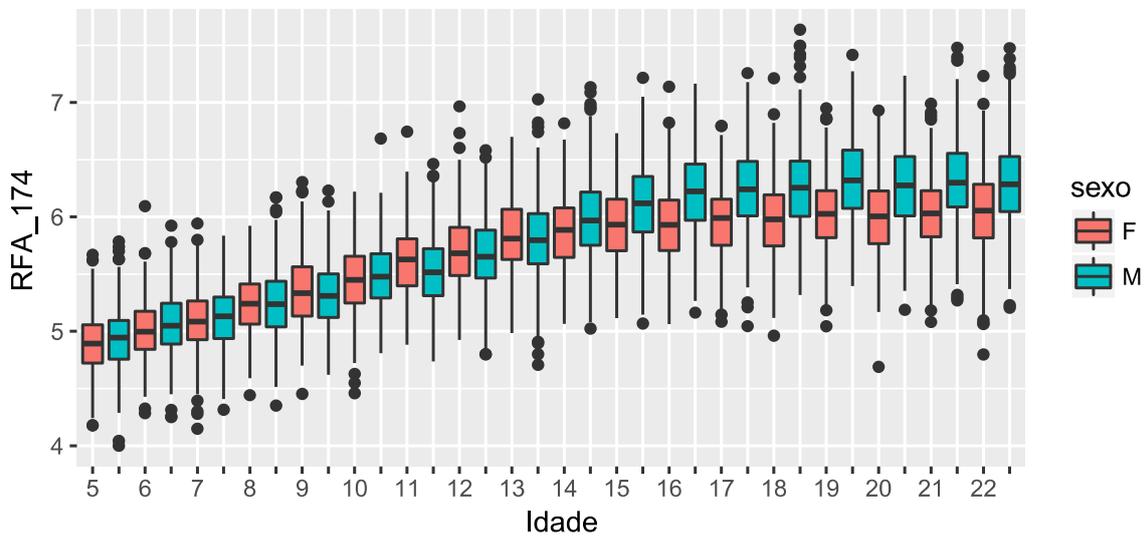
Distribuições da RFA_198 por Sexo e Idade

idades de 5 até 22 anos



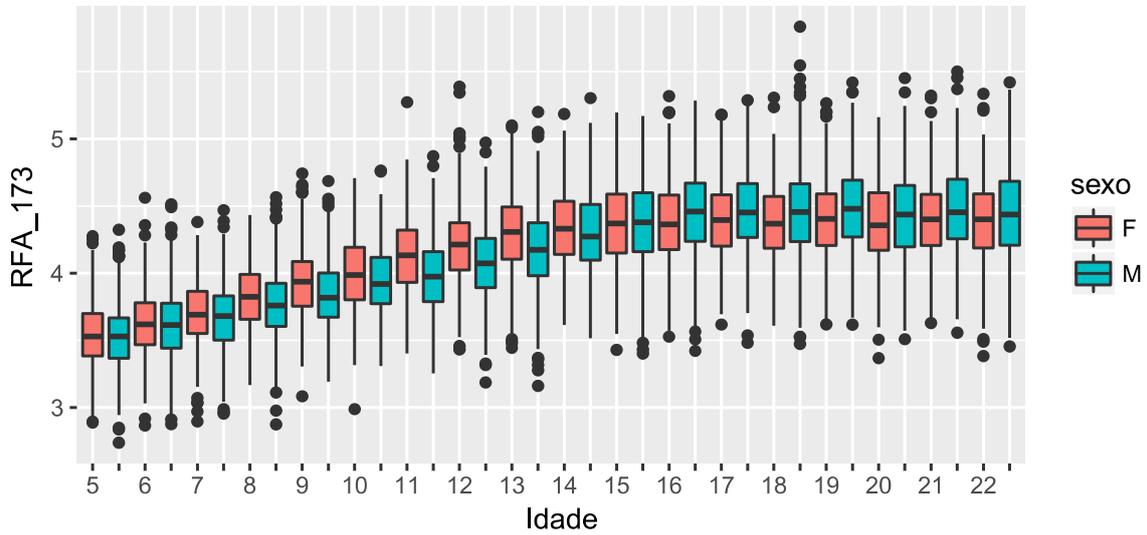
Distribuições da RFA_174 por Sexo e Idade

idades de 5 até 22 anos



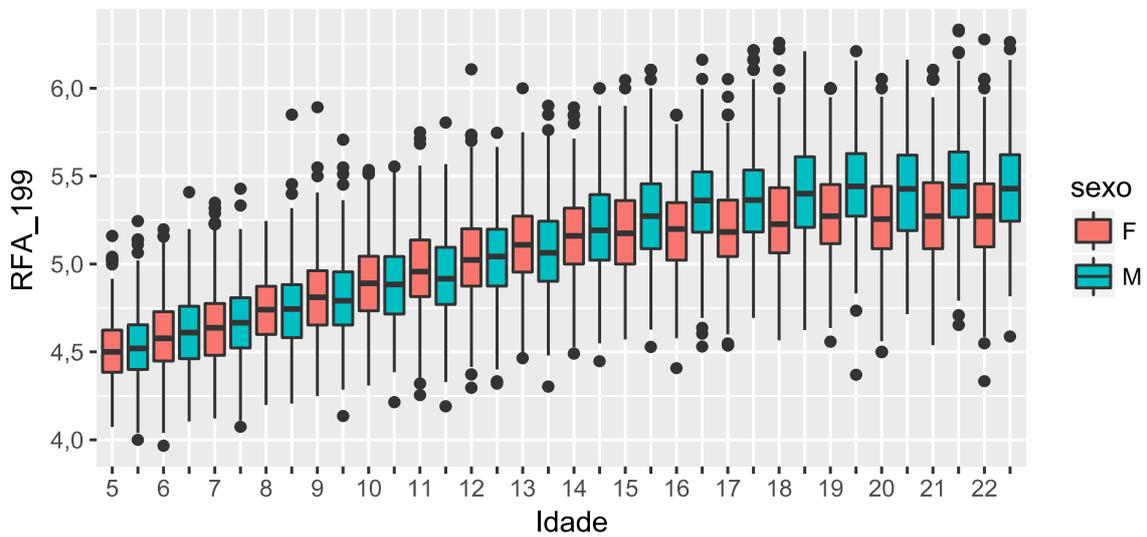
Distribuições da RFA_173 por Sexo e Idade

idades de 5 até 22 anos



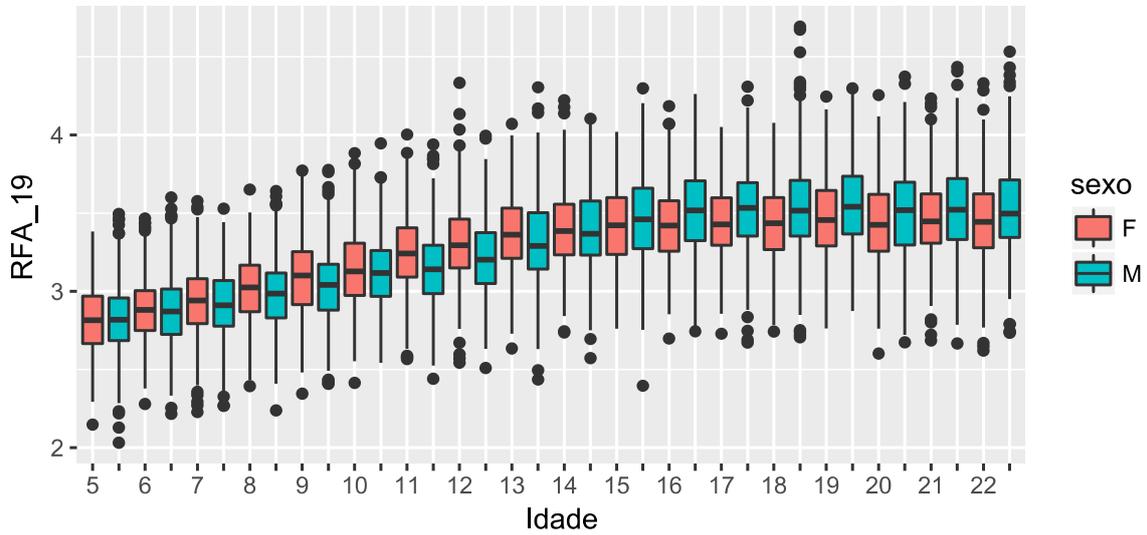
Distribuições da RFA_199 por Sexo e Idade

idades de 5 até 22 anos



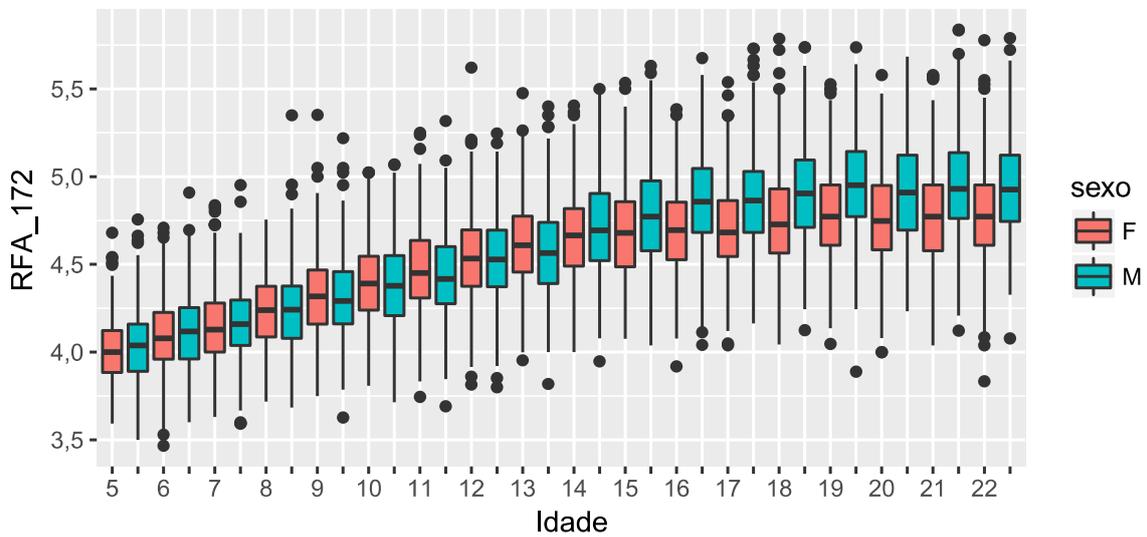
Distribuições da RFA_19 por Sexo e Idade

idades de 5 até 22 anos



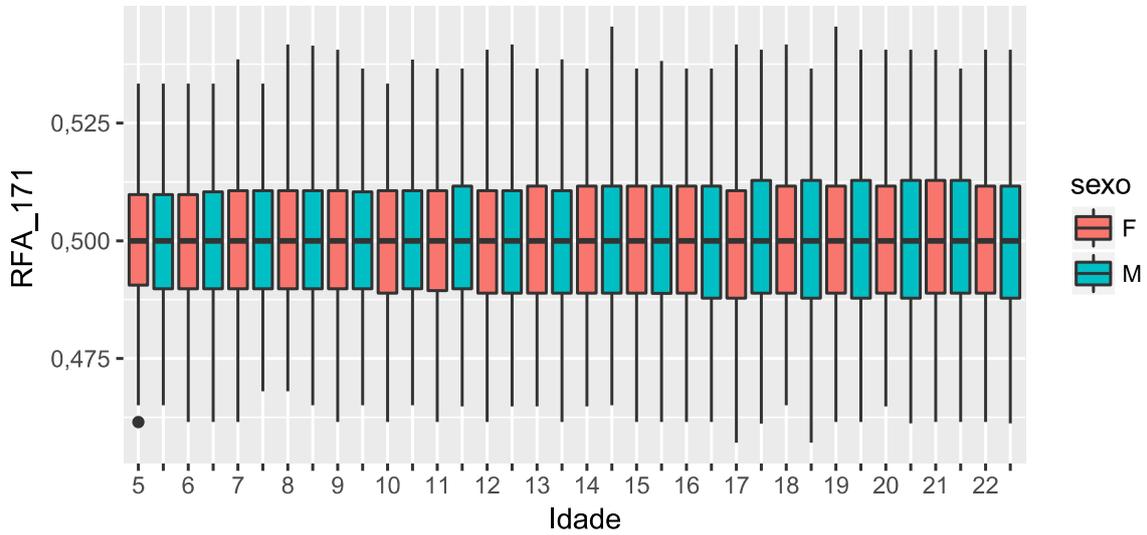
Distribuições da RFA_172 por Sexo e Idade

idades de 5 até 22 anos



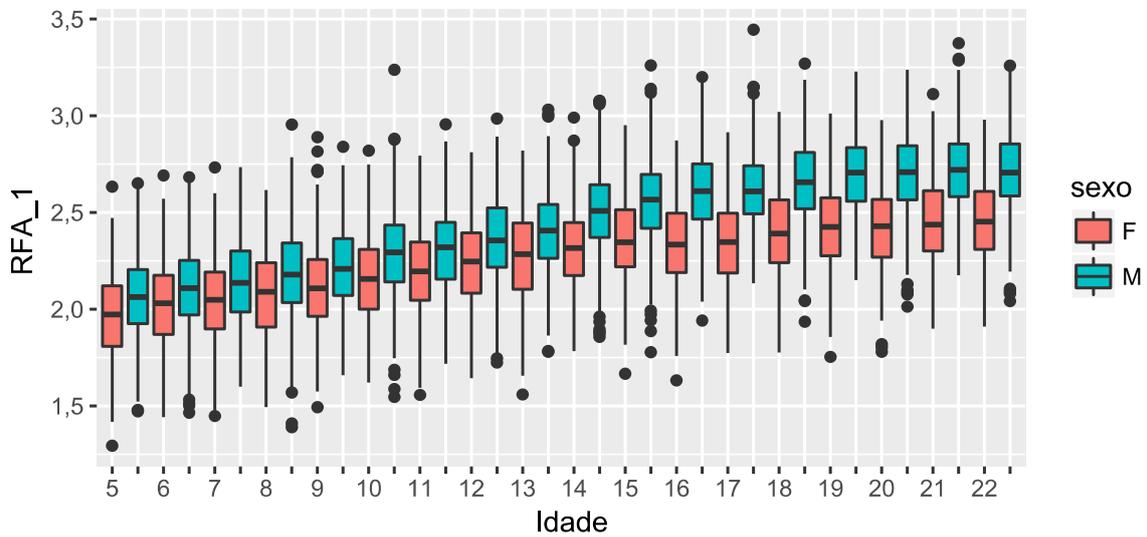
Distribuições da RFA_171 por Sexo e Idade

idades de 5 até 22 anos



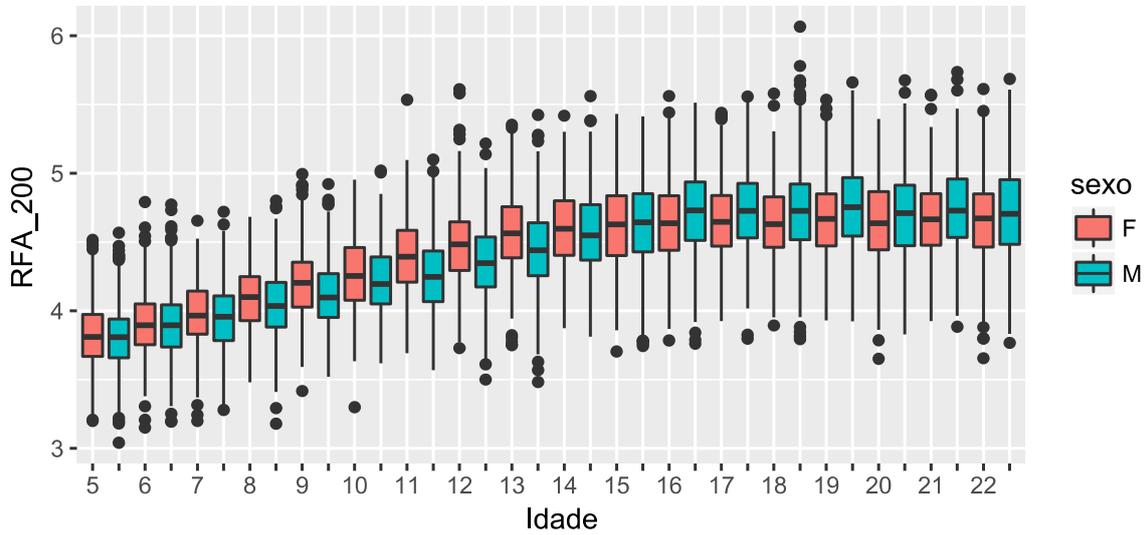
Distribuições da RFA_1 por Sexo e Idade

idades de 5 até 22 anos



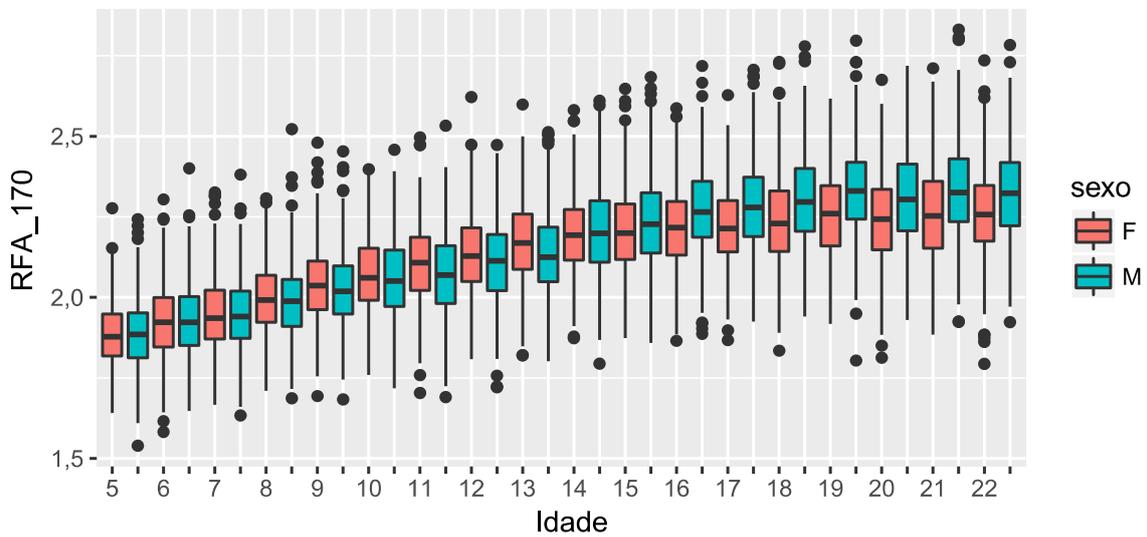
Distribuições da RFA_200 por Sexo e Idade

idades de 5 até 22 anos



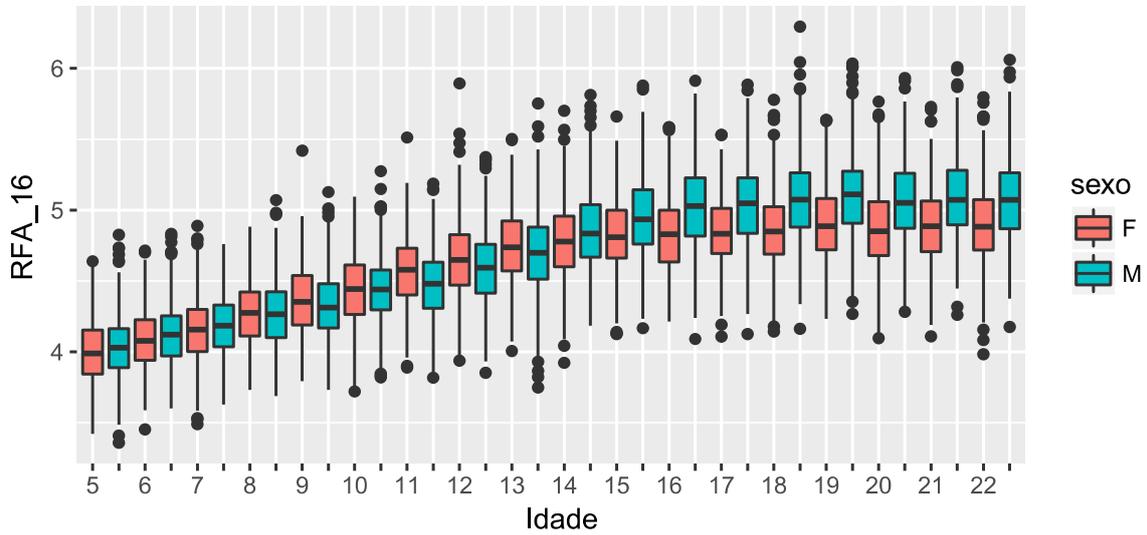
Distribuições da RFA_170 por Sexo e Idade

idades de 5 até 22 anos



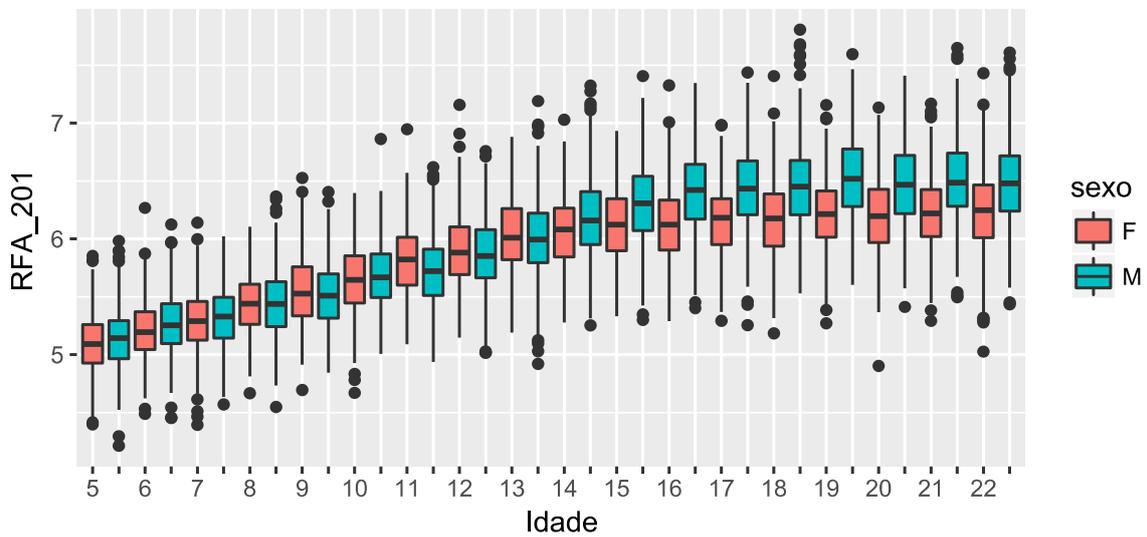
Distribuições da RFA_16 por Sexo e Idade

idades de 5 até 22 anos



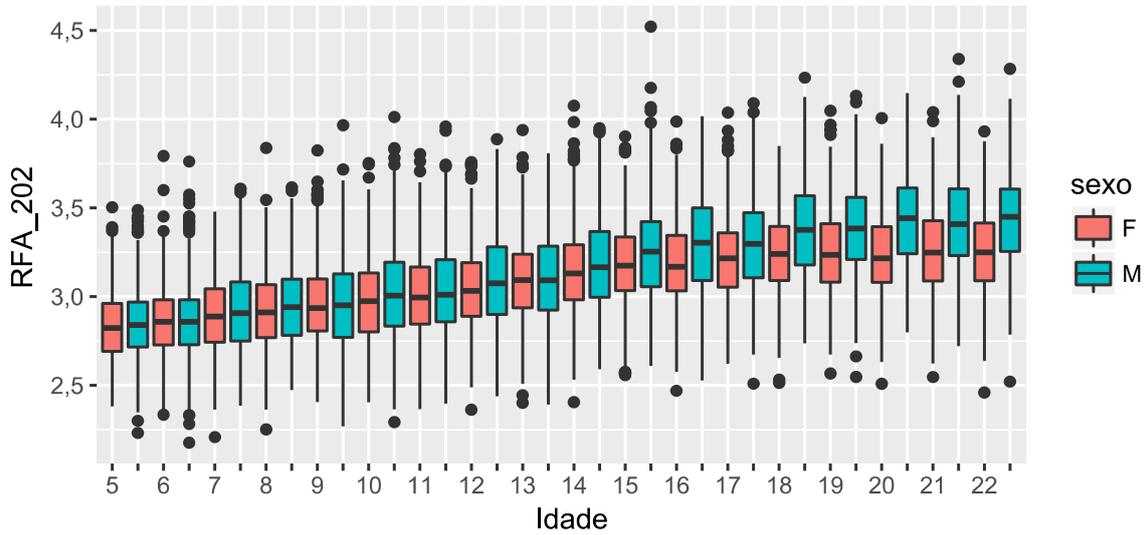
Distribuições da RFA_201 por Sexo e Idade

idades de 5 até 22 anos



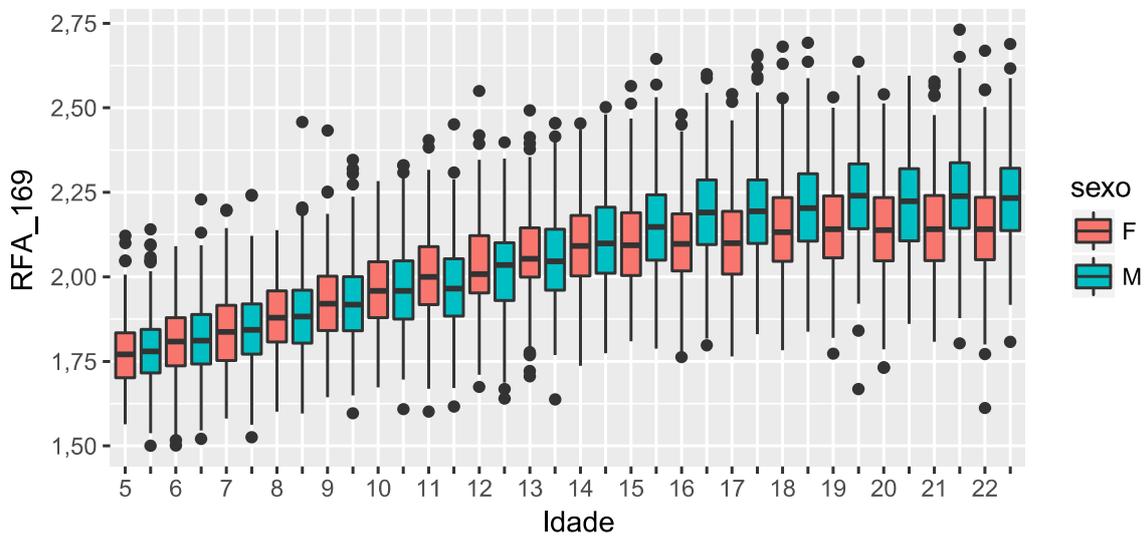
Distribuições da RFA_202 por Sexo e Idade

idades de 5 até 22 anos



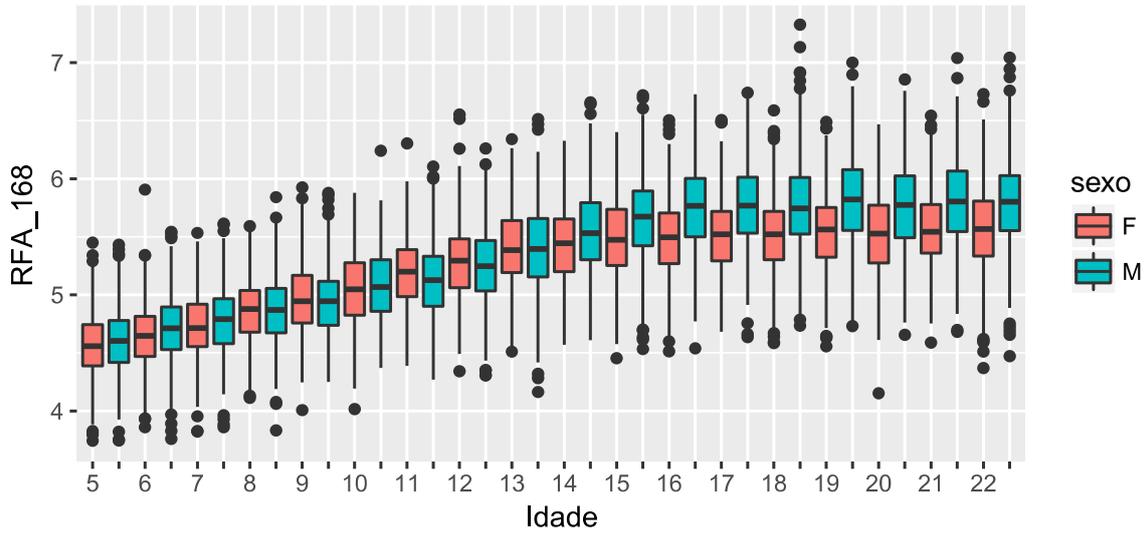
Distribuições da RFA_169 por Sexo e Idade

idades de 5 até 22 anos



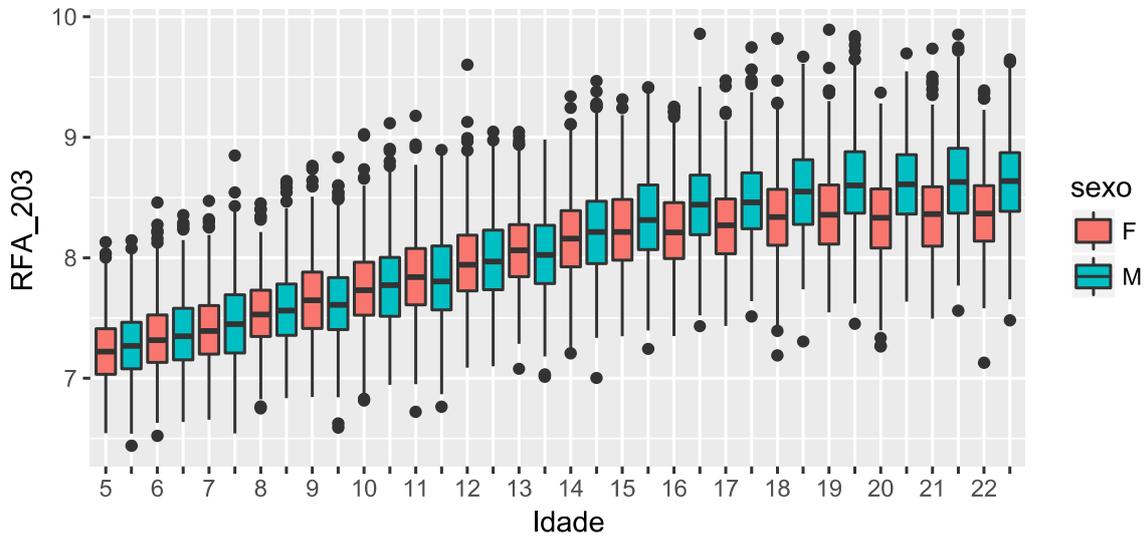
Distribuições da RFA_168 por Sexo e Idade

idades de 5 até 22 anos



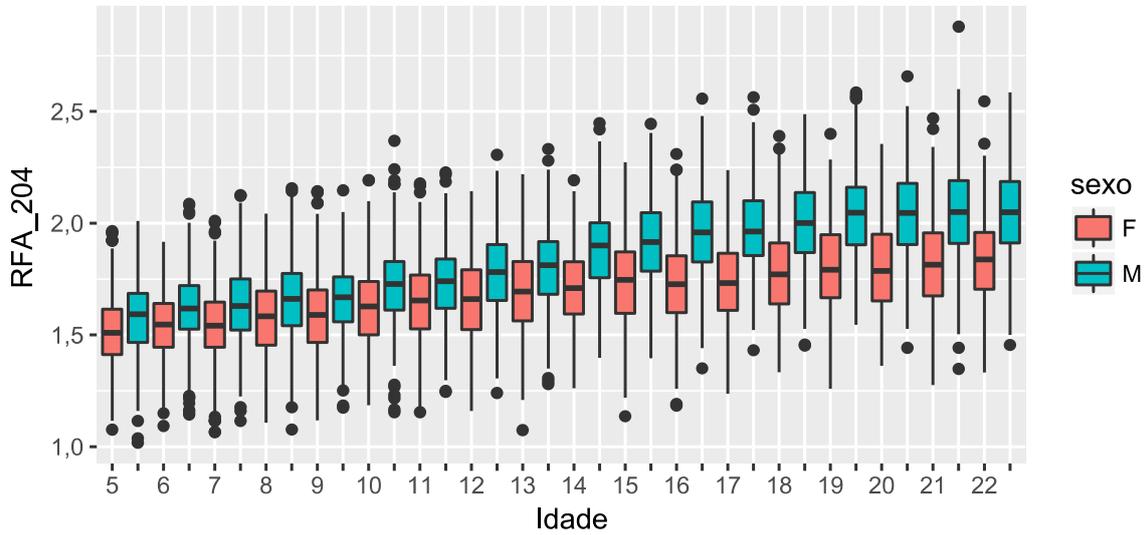
Distribuições da RFA_203 por Sexo e Idade

idades de 5 até 22 anos



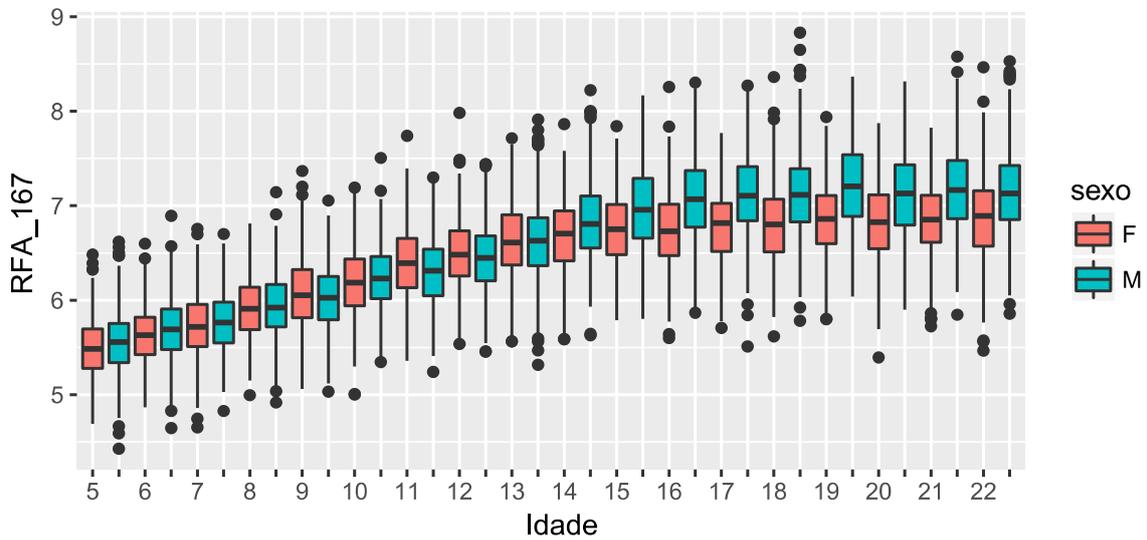
Distribuições da RFA_204 por Sexo e Idade

idades de 5 até 22 anos



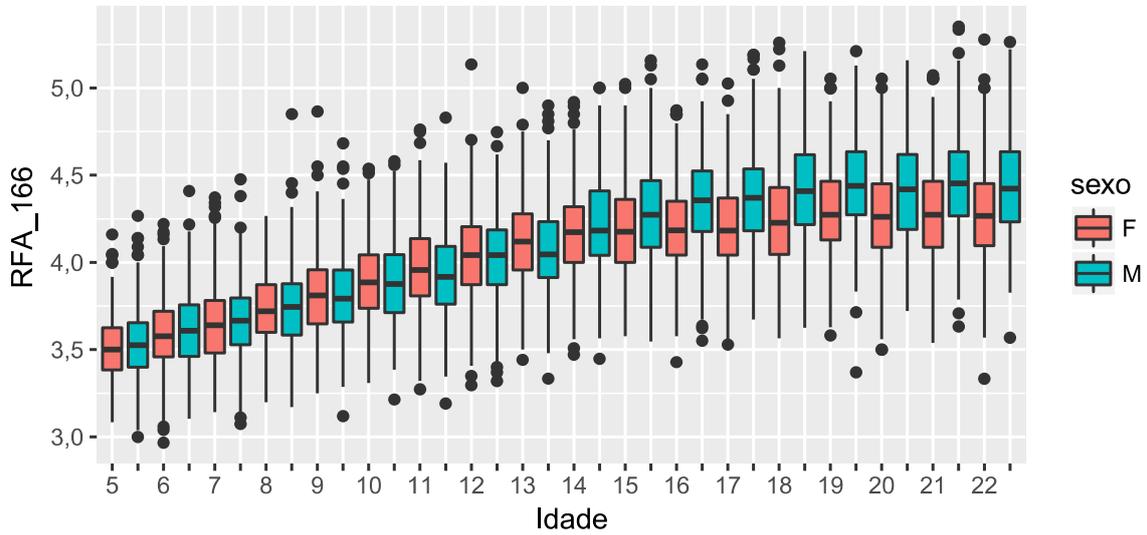
Distribuições da RFA_167 por Sexo e Idade

idades de 5 até 22 anos



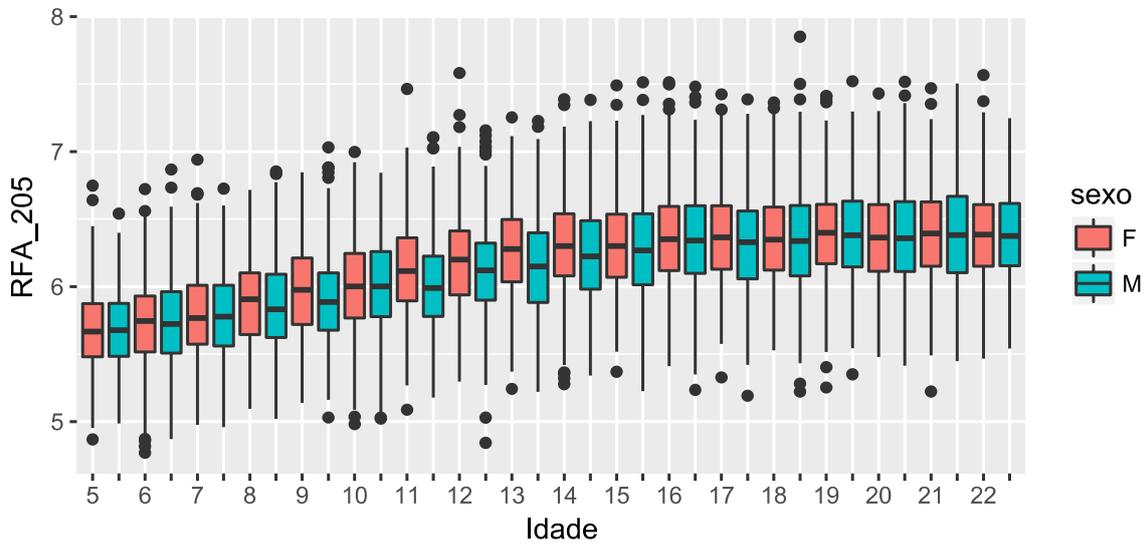
Distribuições da RFA_166 por Sexo e Idade

idades de 5 até 22 anos



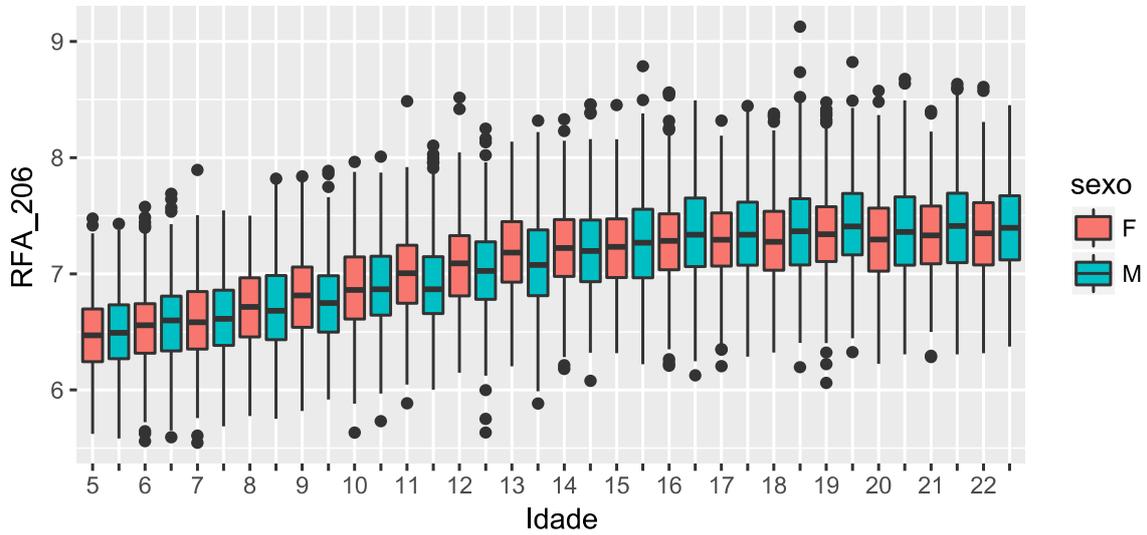
Distribuições da RFA_205 por Sexo e Idade

idades de 5 até 22 anos



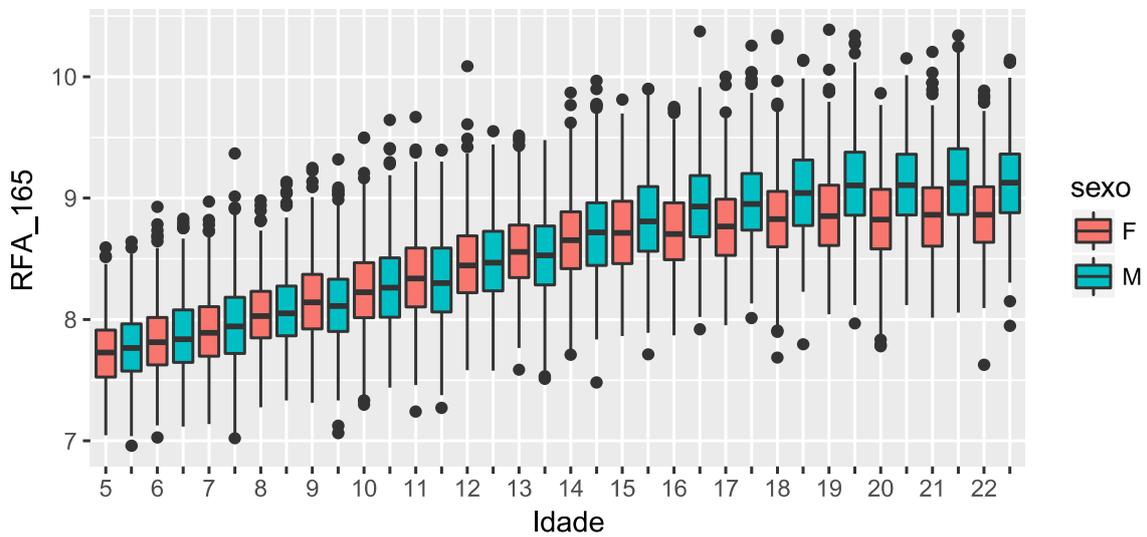
Distribuições da RFA_206 por Sexo e Idade

idades de 5 até 22 anos



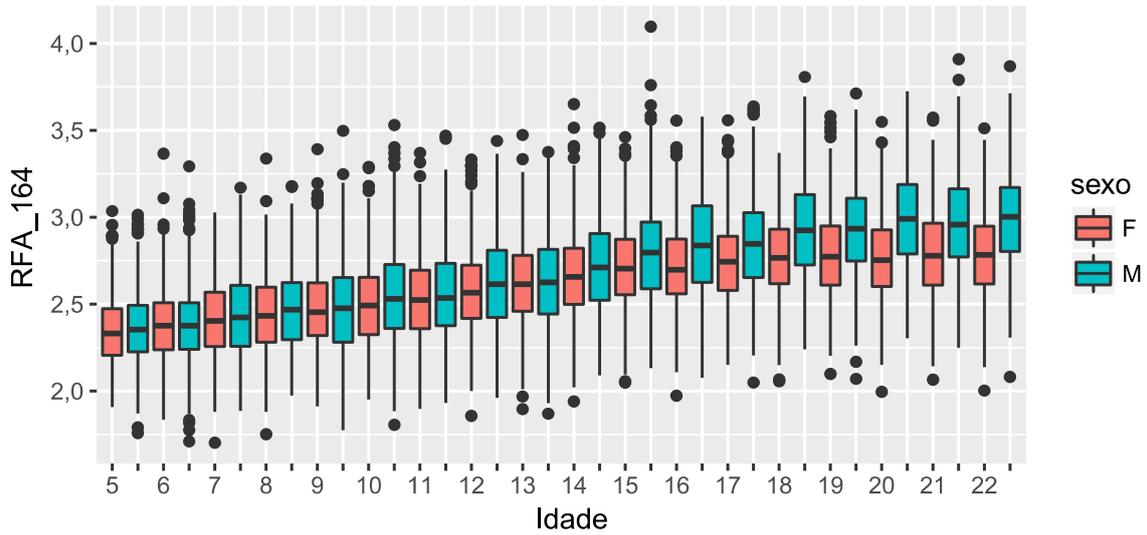
Distribuições da RFA_165 por Sexo e Idade

idades de 5 até 22 anos



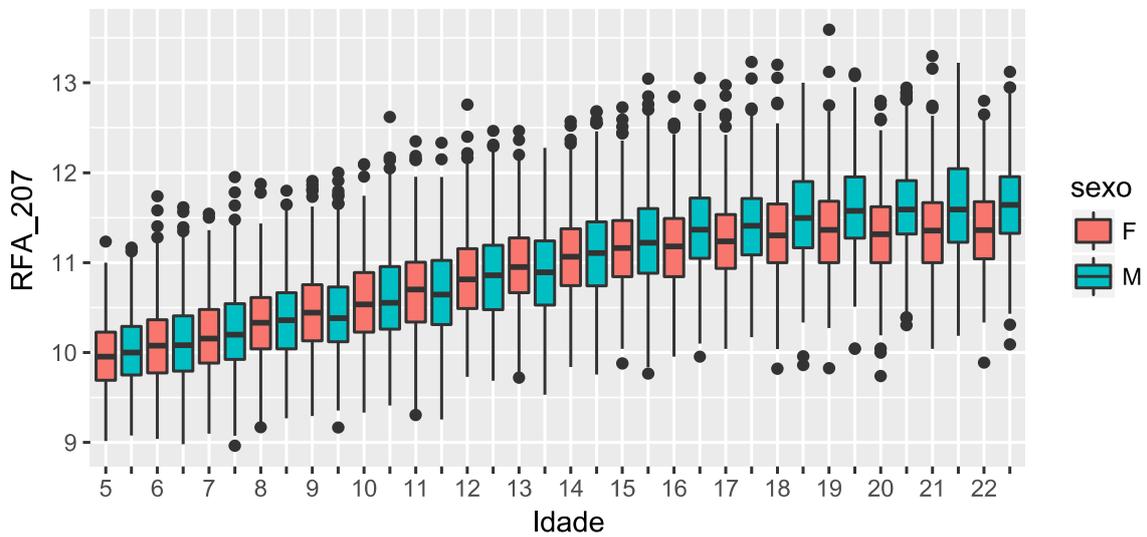
Distribuições da RFA_164 por Sexo e Idade

idades de 5 até 22 anos



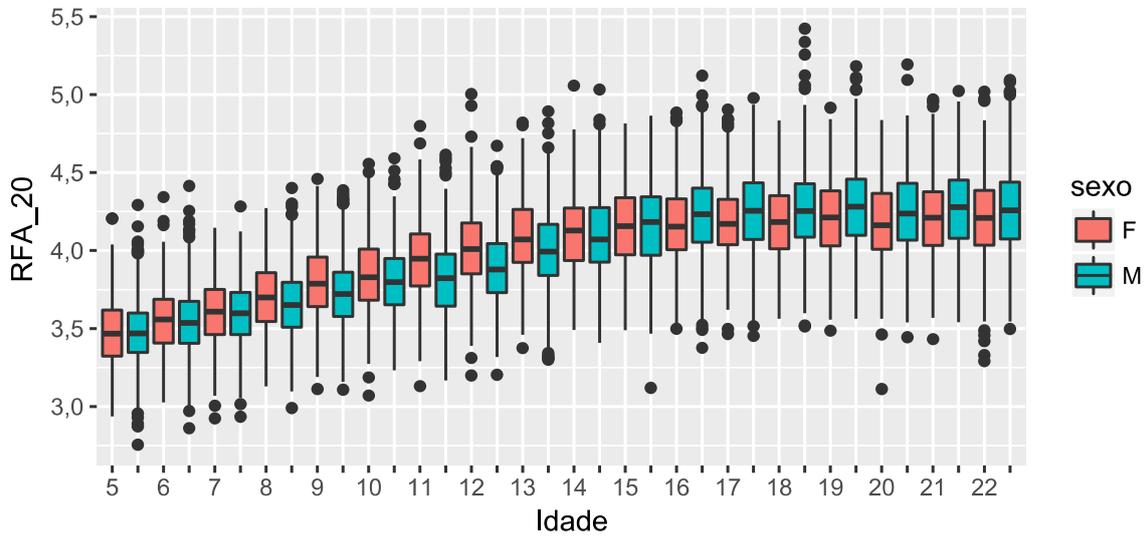
Distribuições da RFA_207 por Sexo e Idade

idades de 5 até 22 anos



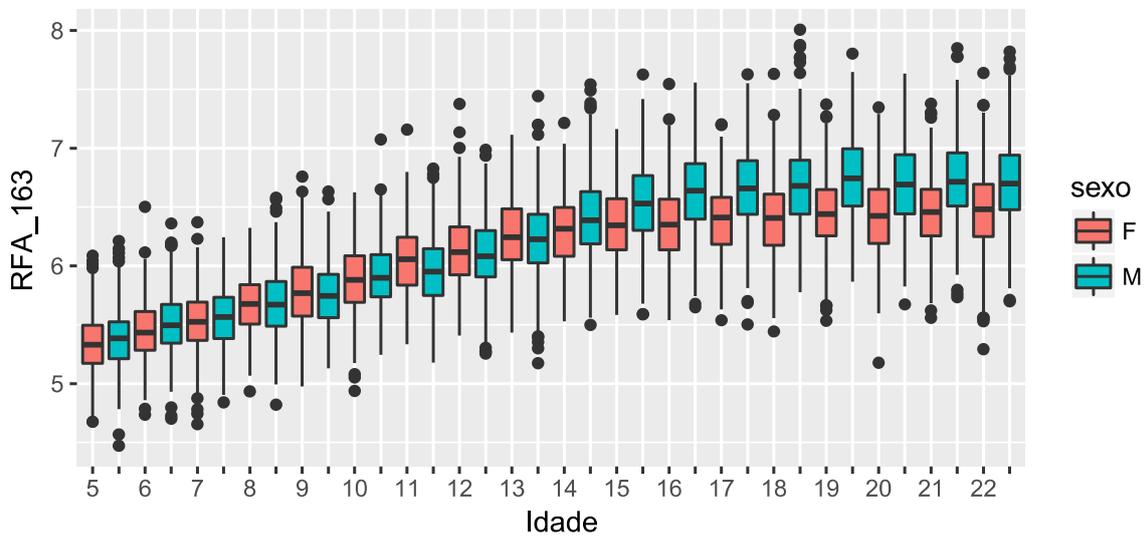
Distribuições da RFA_20 por Sexo e Idade

idades de 5 até 22 anos



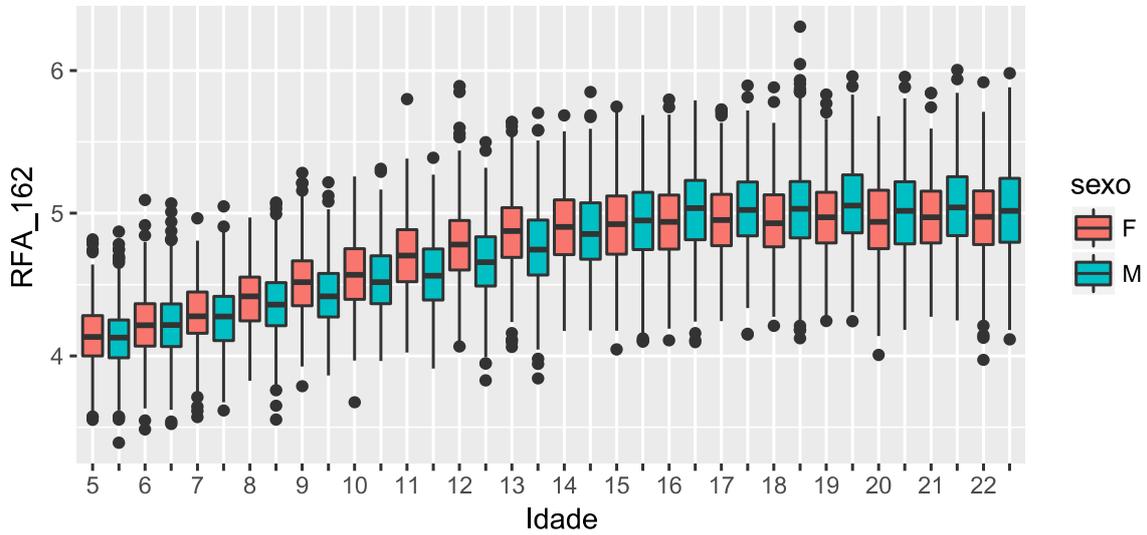
Distribuições da RFA_163 por Sexo e Idade

idades de 5 até 22 anos



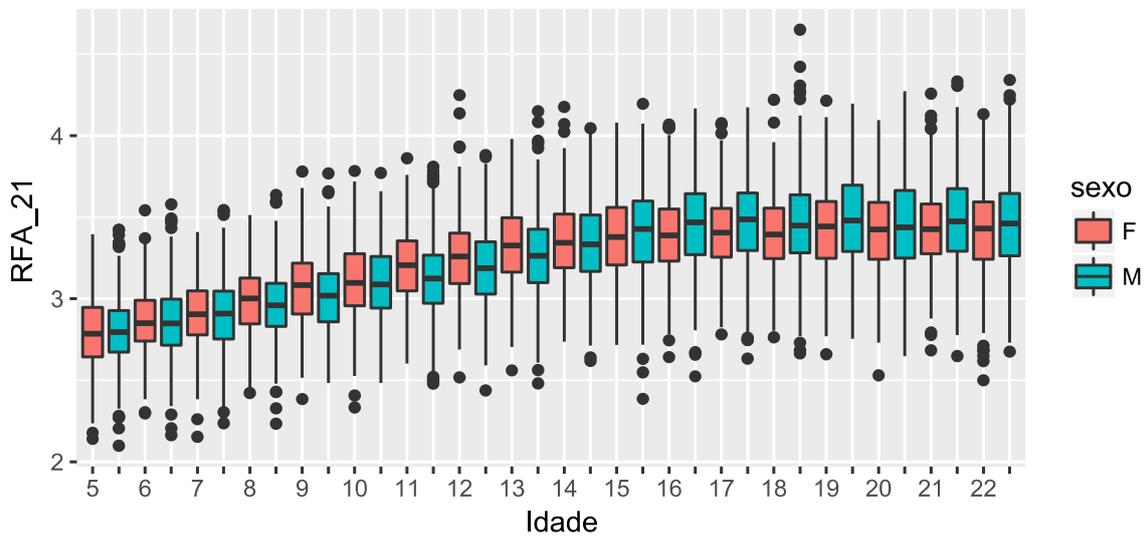
Distribuições da RFA_162 por Sexo e Idade

idades de 5 até 22 anos



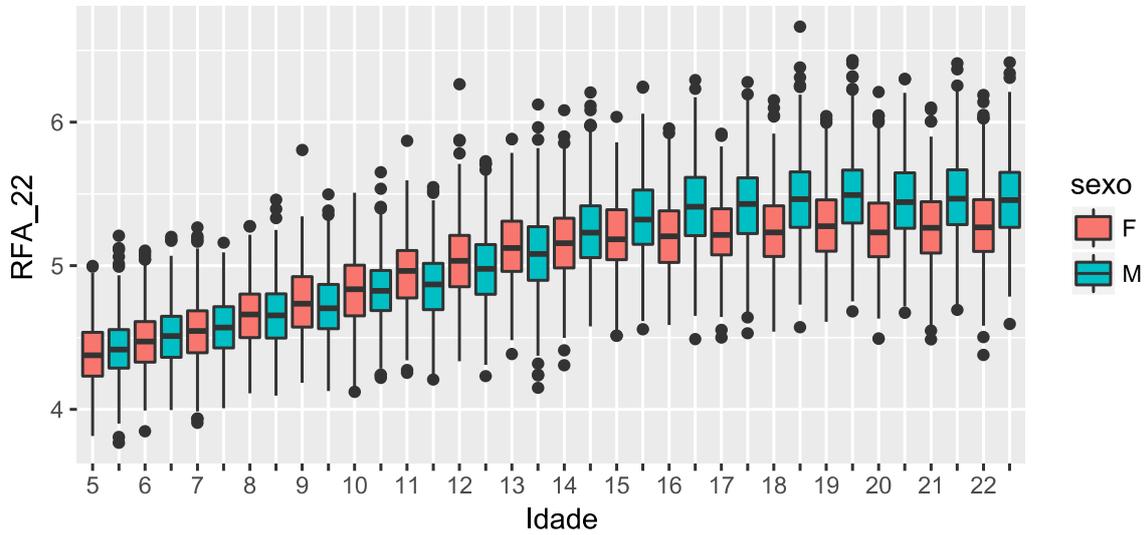
Distribuições da RFA_21 por Sexo e Idade

idades de 5 até 22 anos



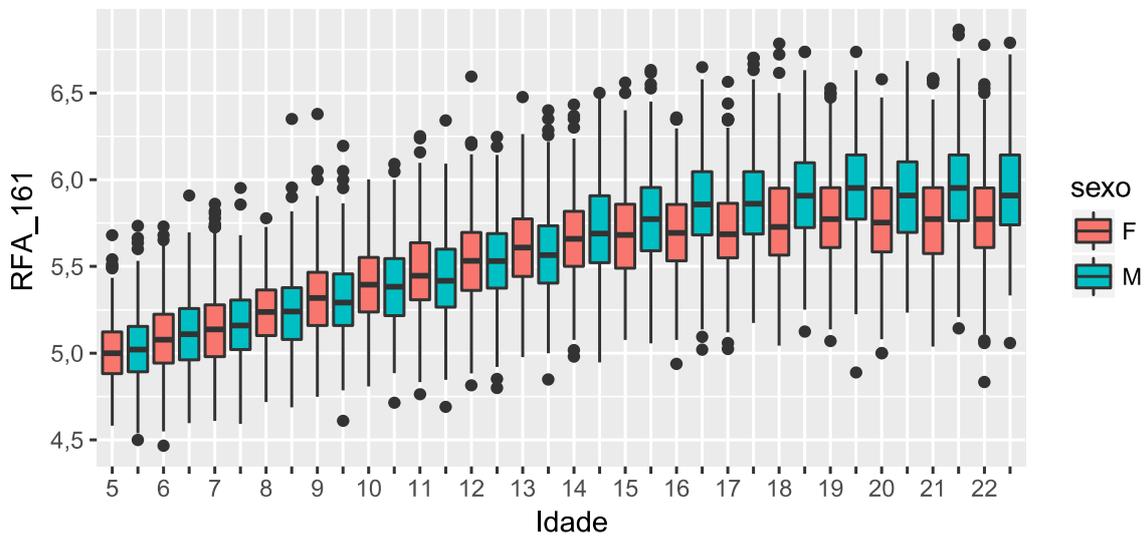
Distribuições da RFA_22 por Sexo e Idade

idades de 5 até 22 anos



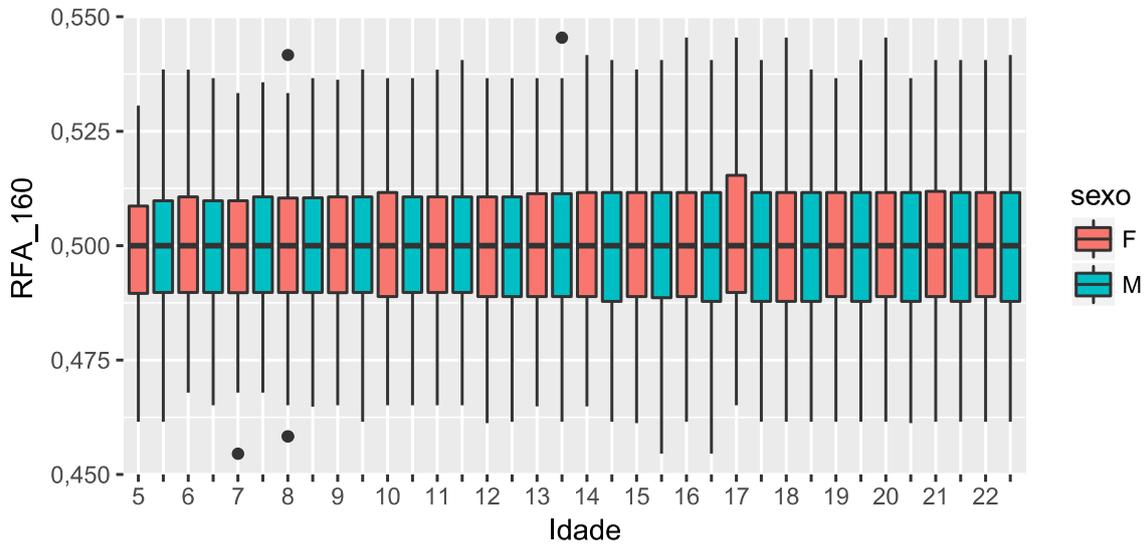
Distribuições da RFA_161 por Sexo e Idade

idades de 5 até 22 anos



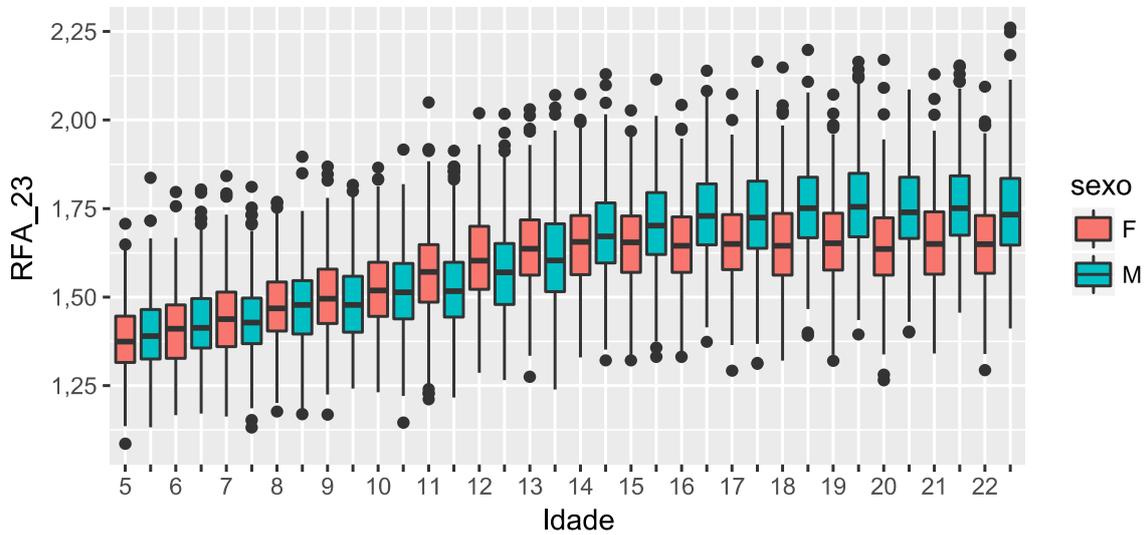
Distribuições da RFA_160 por Sexo e Idade

idades de 5 até 22 anos



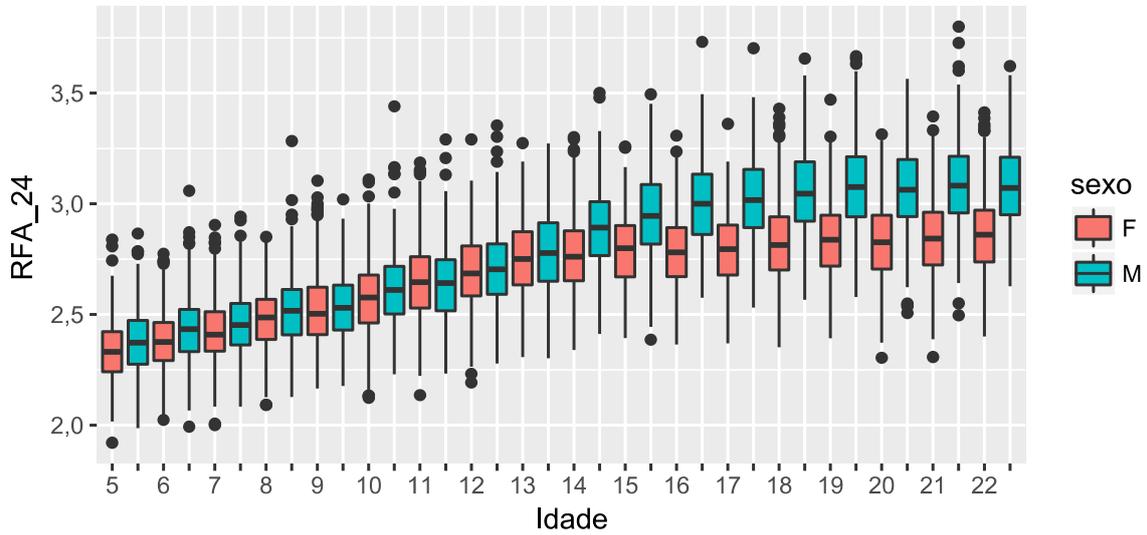
Distribuições da RFA_23 por Sexo e Idade

idades de 5 até 22 anos



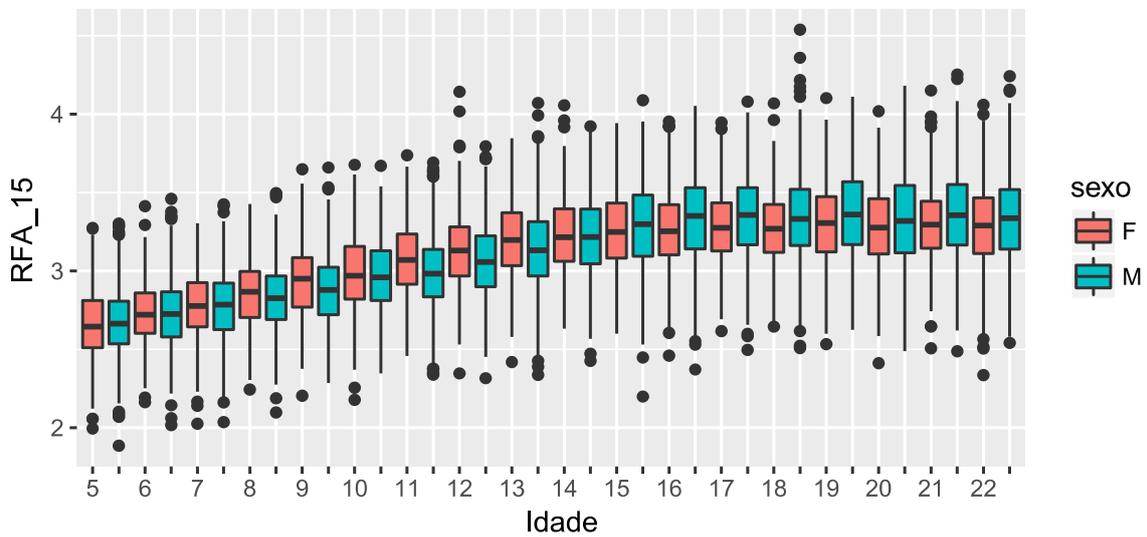
Distribuições da RFA_24 por Sexo e Idade

idades de 5 até 22 anos



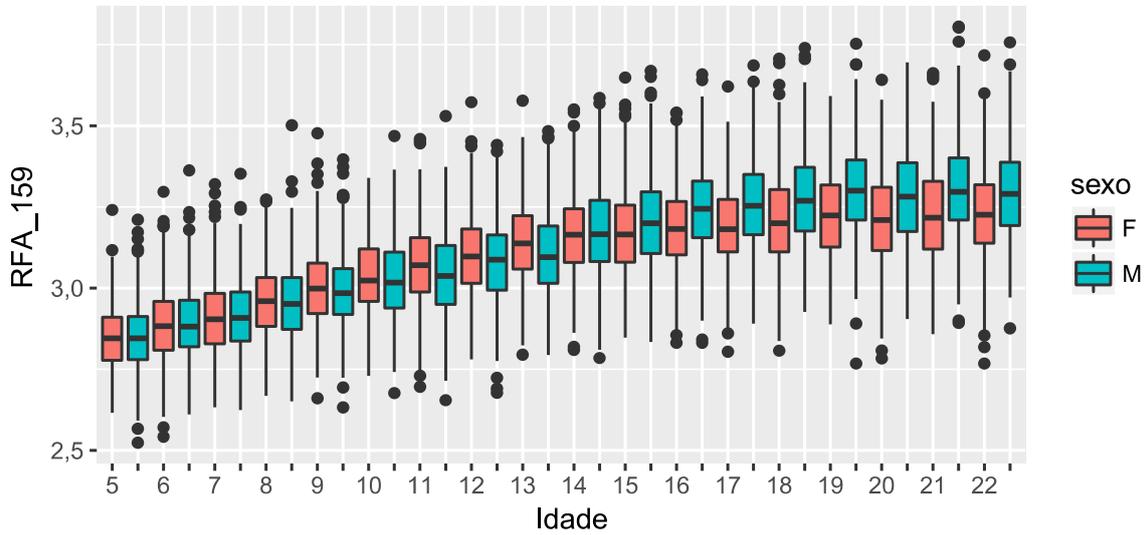
Distribuições da RFA_15 por Sexo e Idade

idades de 5 até 22 anos



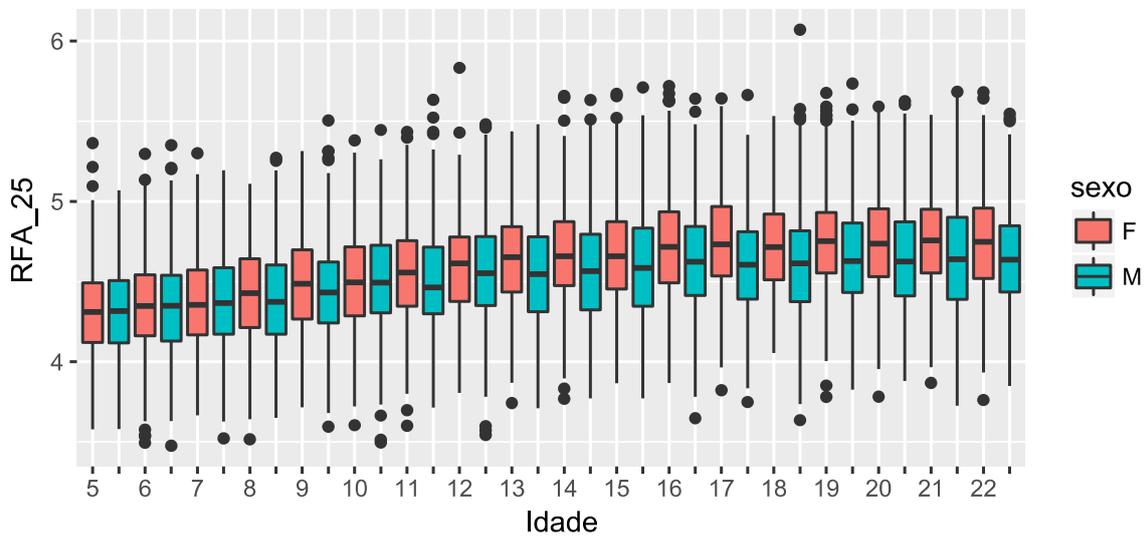
Distribuições da RFA_159 por Sexo e Idade

idades de 5 até 22 anos



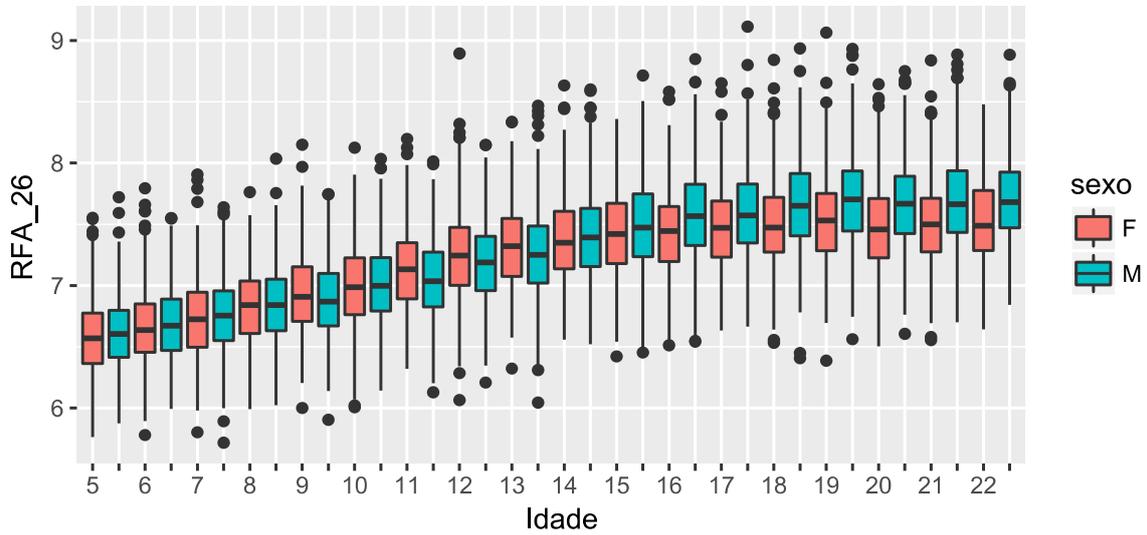
Distribuições da RFA_25 por Sexo e Idade

idades de 5 até 22 anos



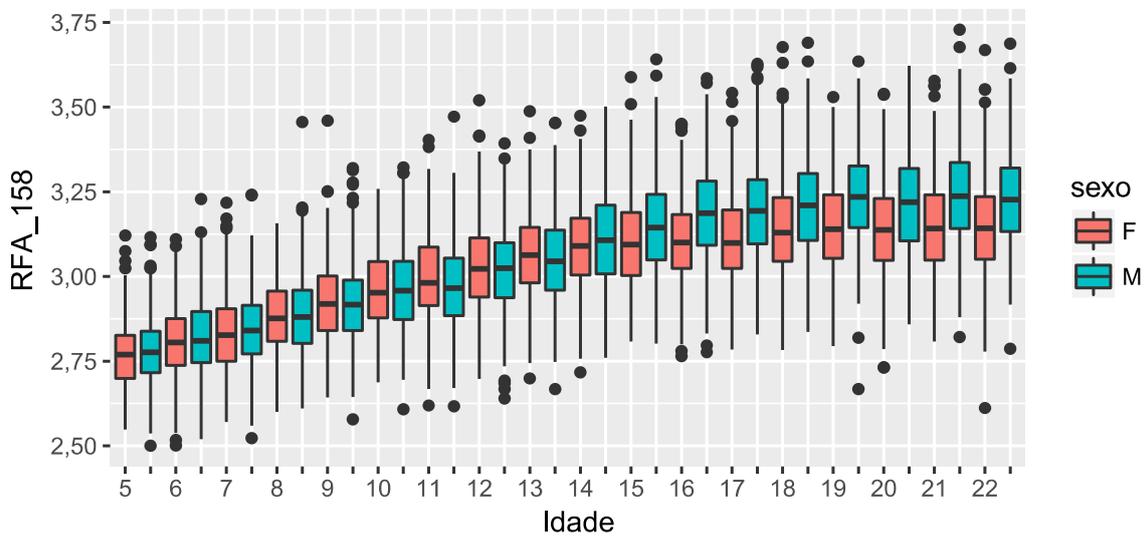
Distribuições da RFA_26 por Sexo e Idade

idades de 5 até 22 anos



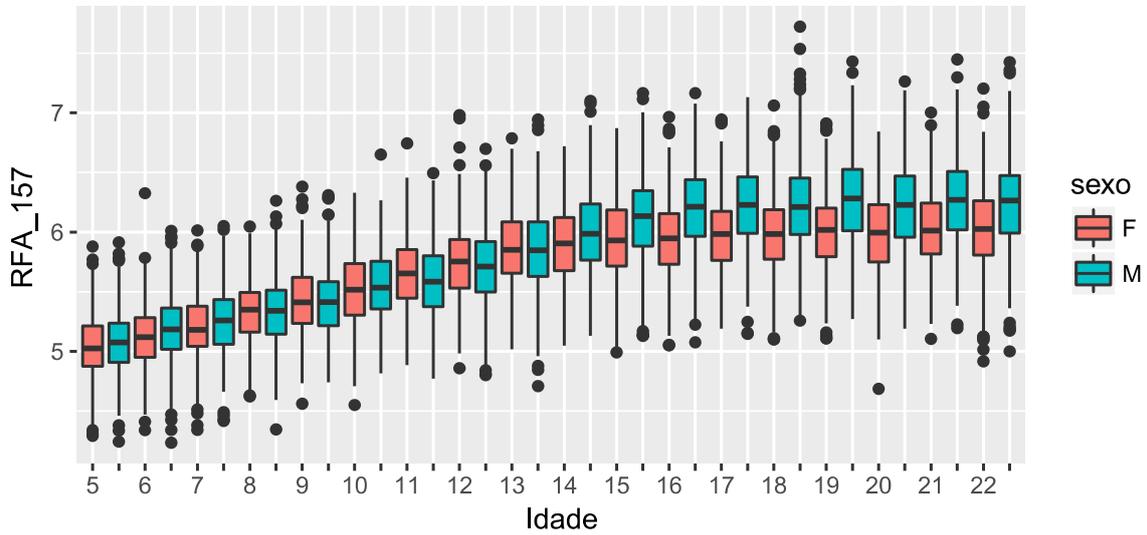
Distribuições da RFA_158 por Sexo e Idade

idades de 5 até 22 anos



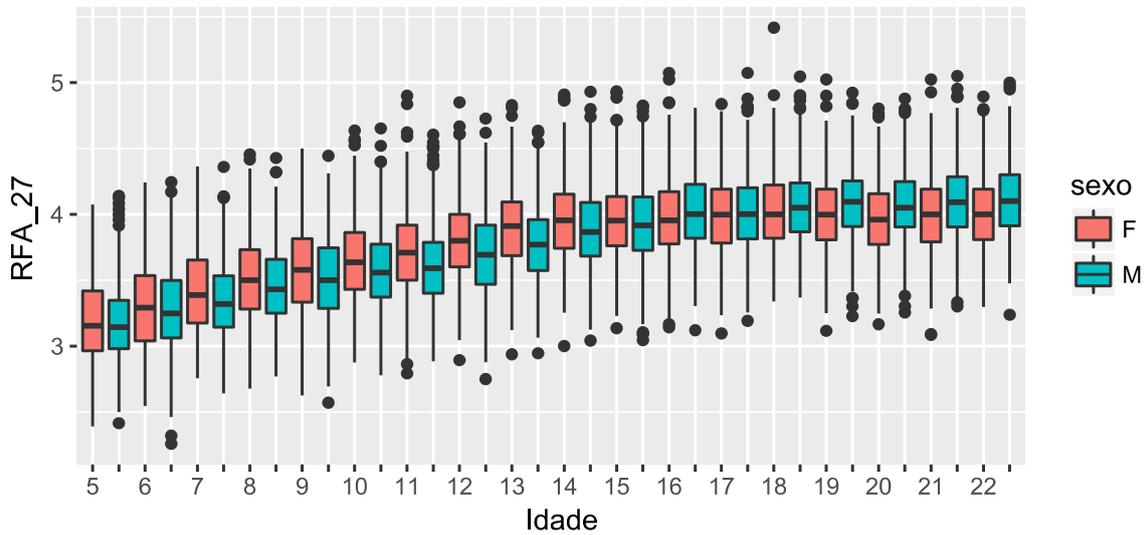
Distribuições da RFA_157 por Sexo e Idade

idades de 5 até 22 anos



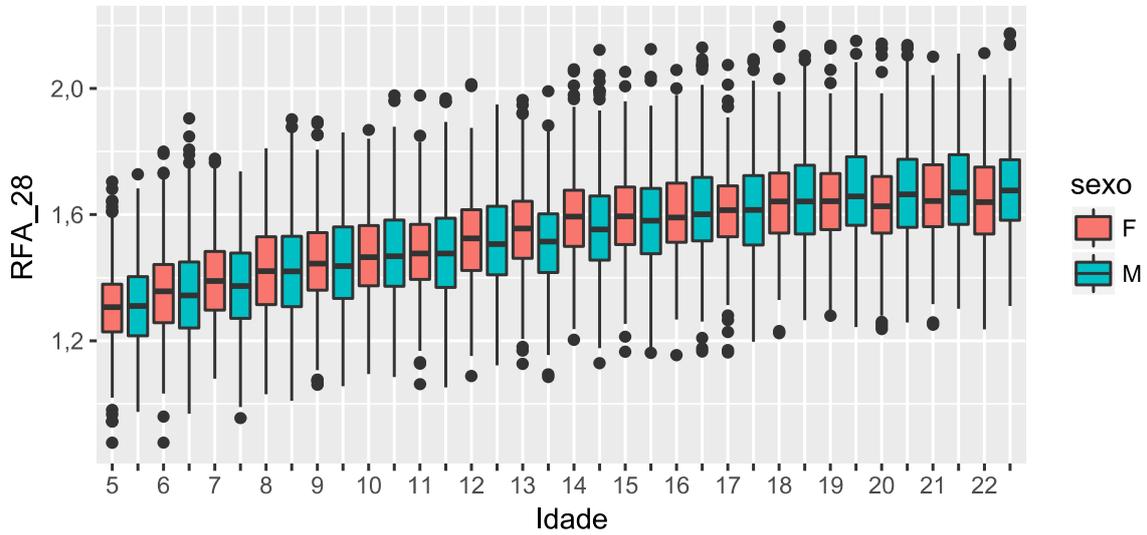
Distribuições da RFA_27 por Sexo e Idade

idades de 5 até 22 anos



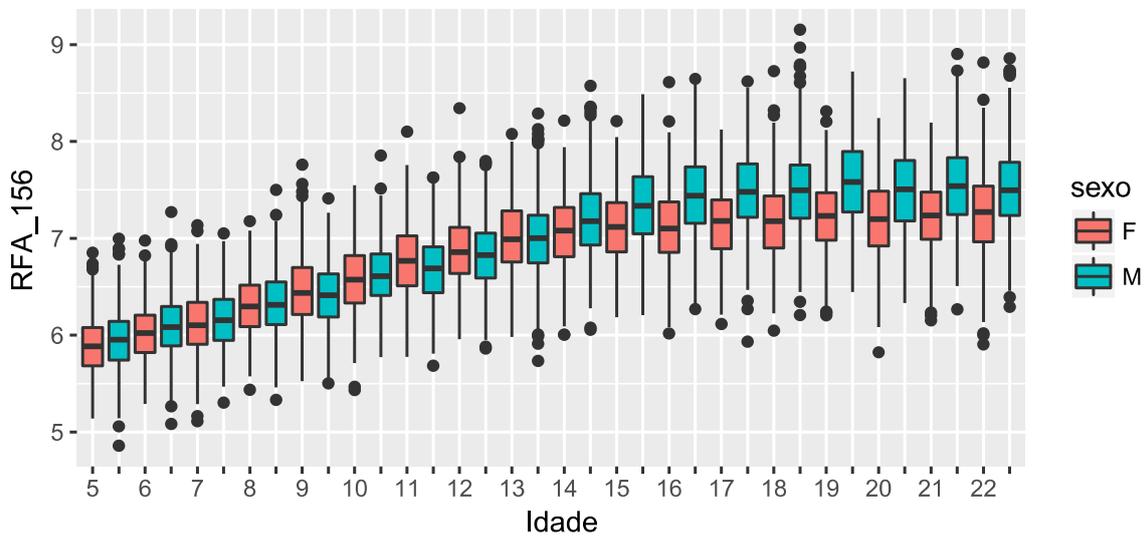
Distribuições da RFA_28 por Sexo e Idade

idades de 5 até 22 anos



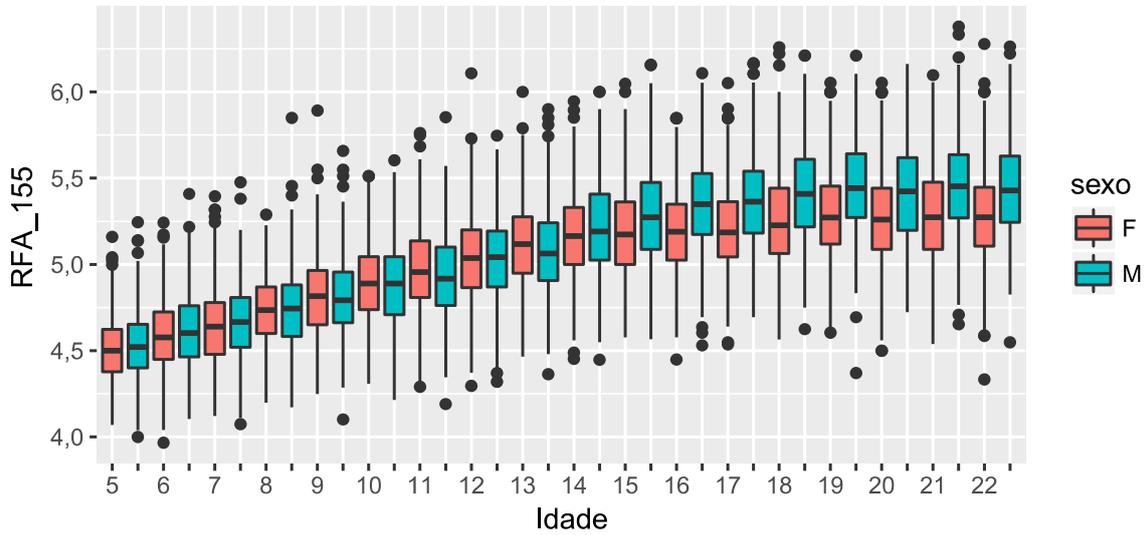
Distribuições da RFA_156 por Sexo e Idade

idades de 5 até 22 anos



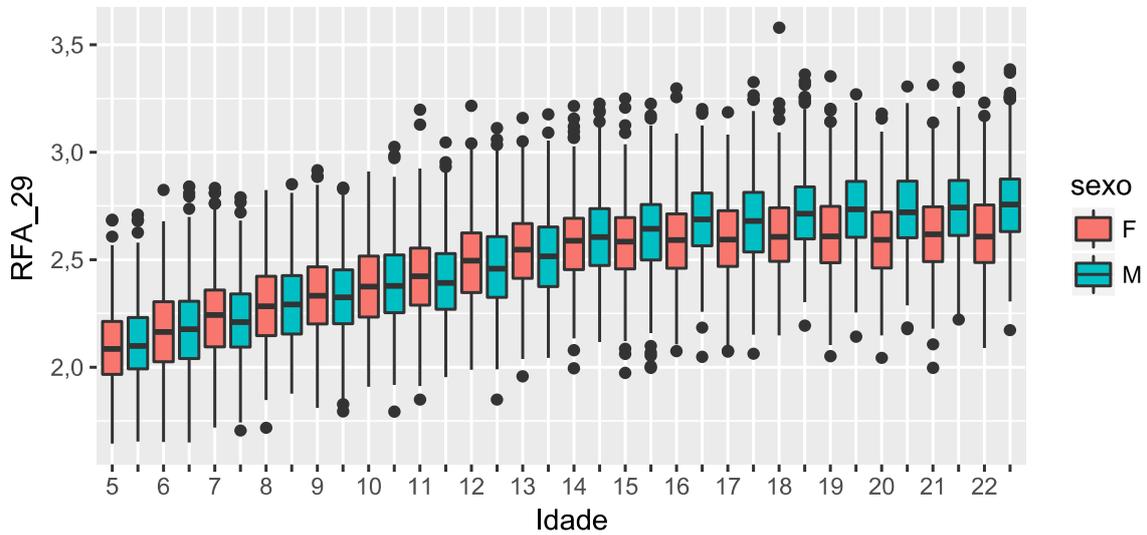
Distribuições da RFA_155 por Sexo e Idade

idades de 5 até 22 anos

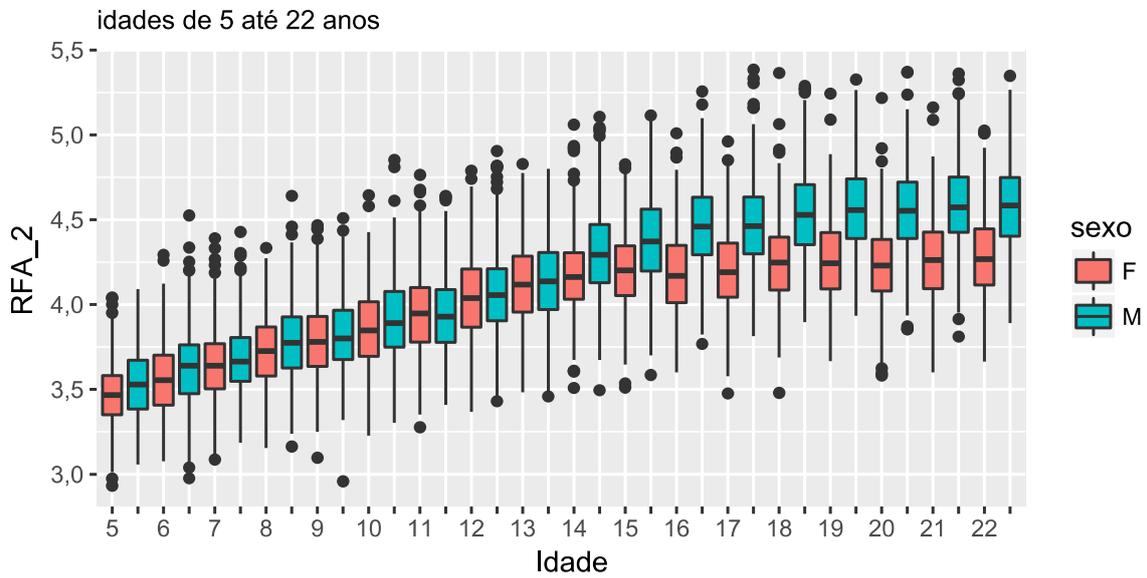


Distribuições da RFA_29 por Sexo e Idade

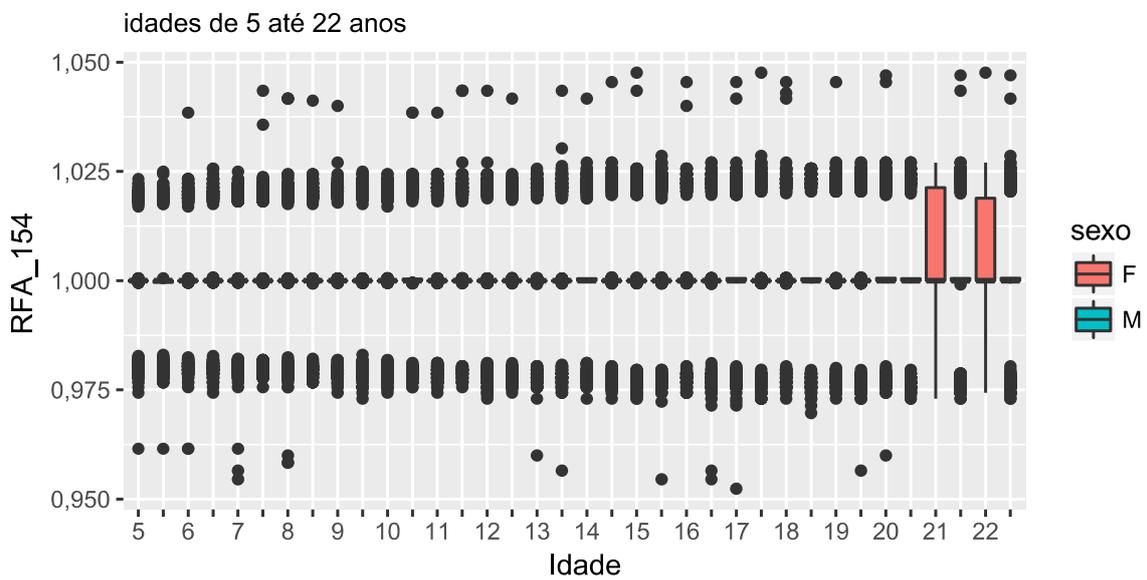
idades de 5 até 22 anos



Distribuições da RFA_2 por Sexo e Idade

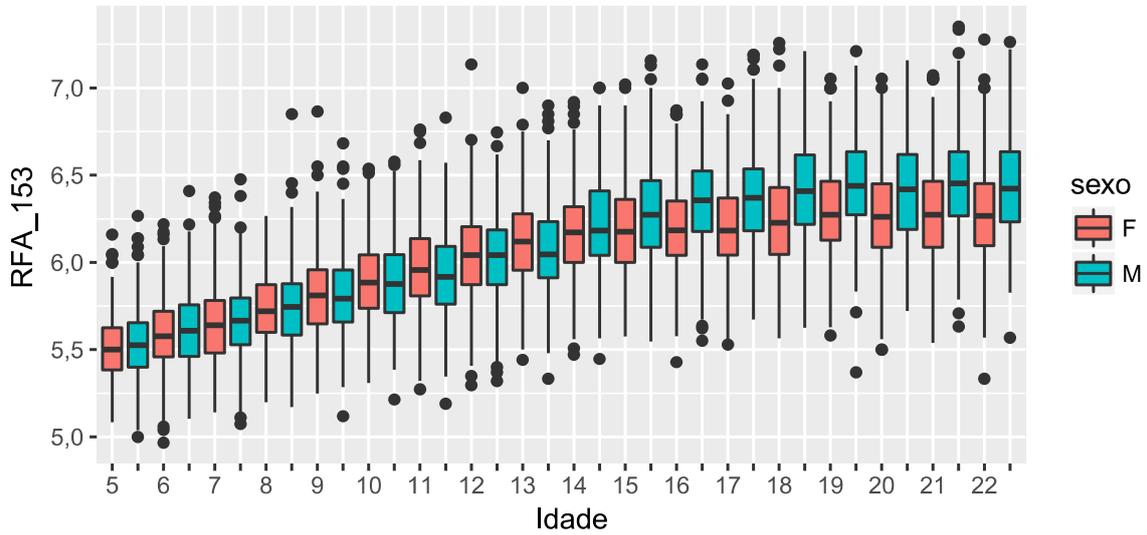


Distribuições da RFA_154 por Sexo e Idade



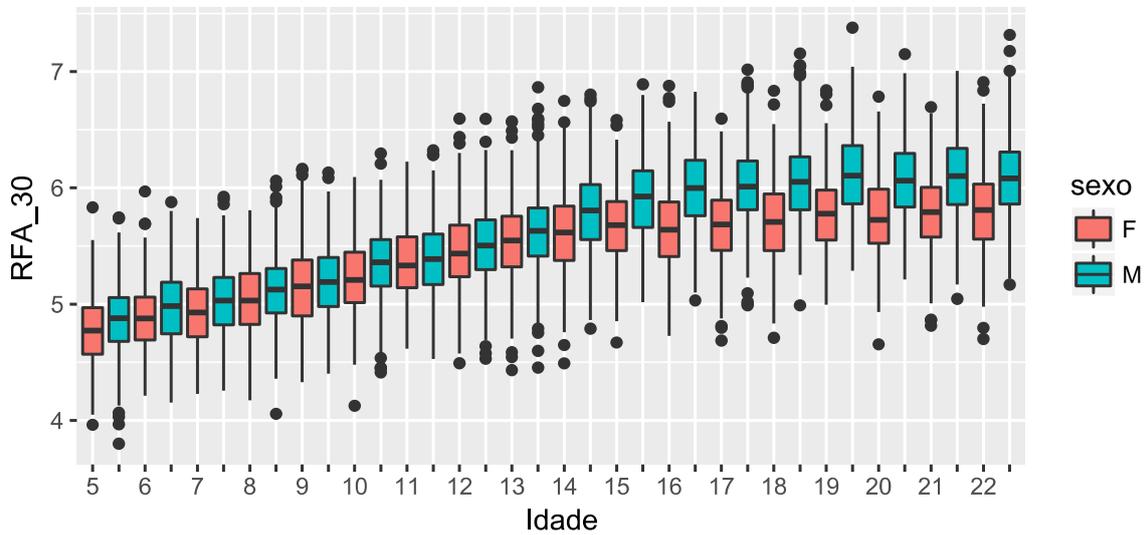
Distribuições da RFA_153 por Sexo e Idade

idades de 5 até 22 anos



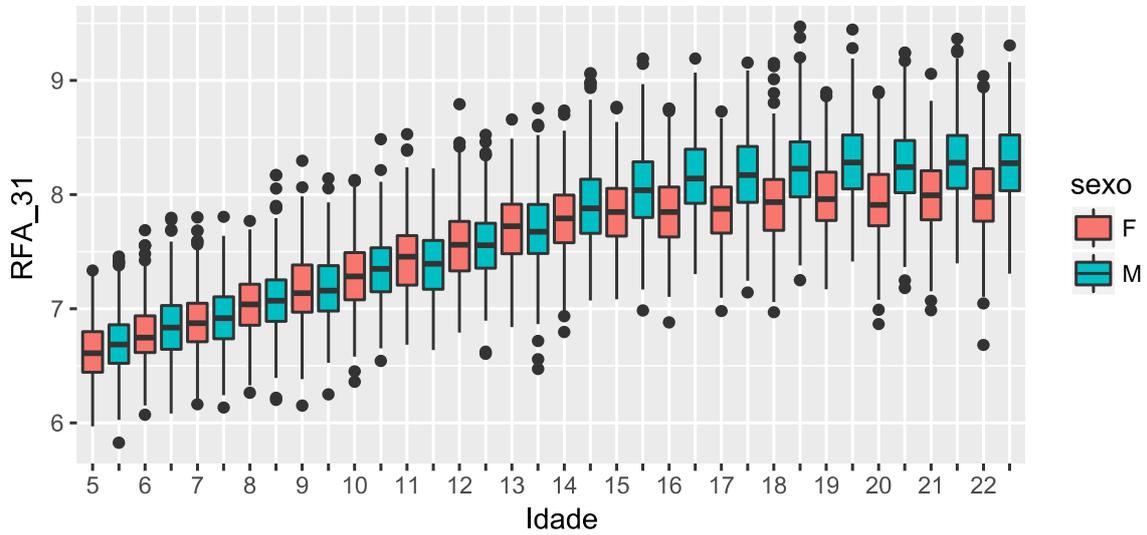
Distribuições da RFA_30 por Sexo e Idade

idades de 5 até 22 anos



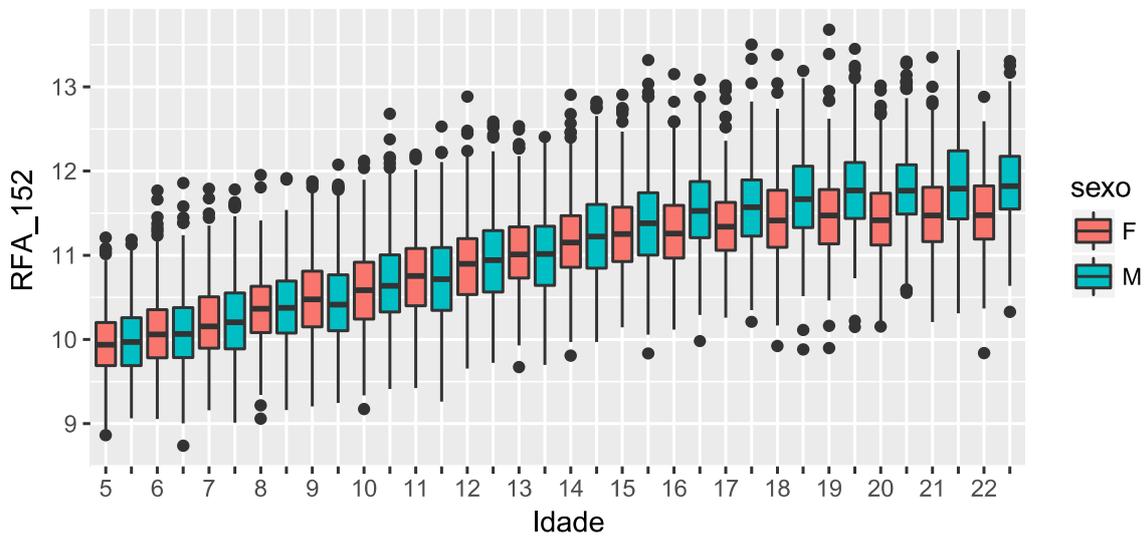
Distribuições da RFA_31 por Sexo e Idade

idades de 5 até 22 anos



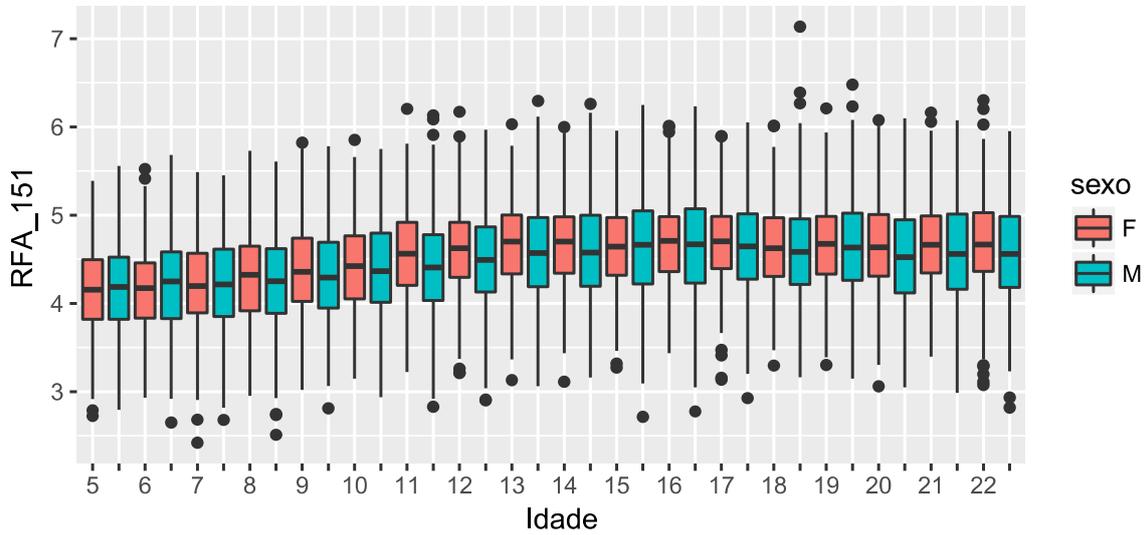
Distribuições da RFA_152 por Sexo e Idade

idades de 5 até 22 anos



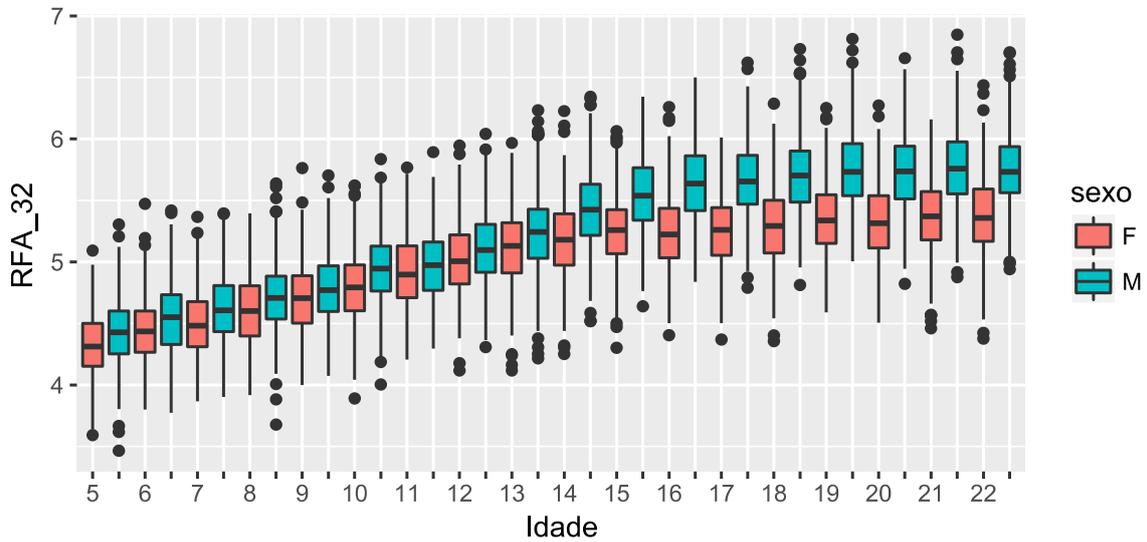
Distribuições da RFA_151 por Sexo e Idade

idades de 5 até 22 anos



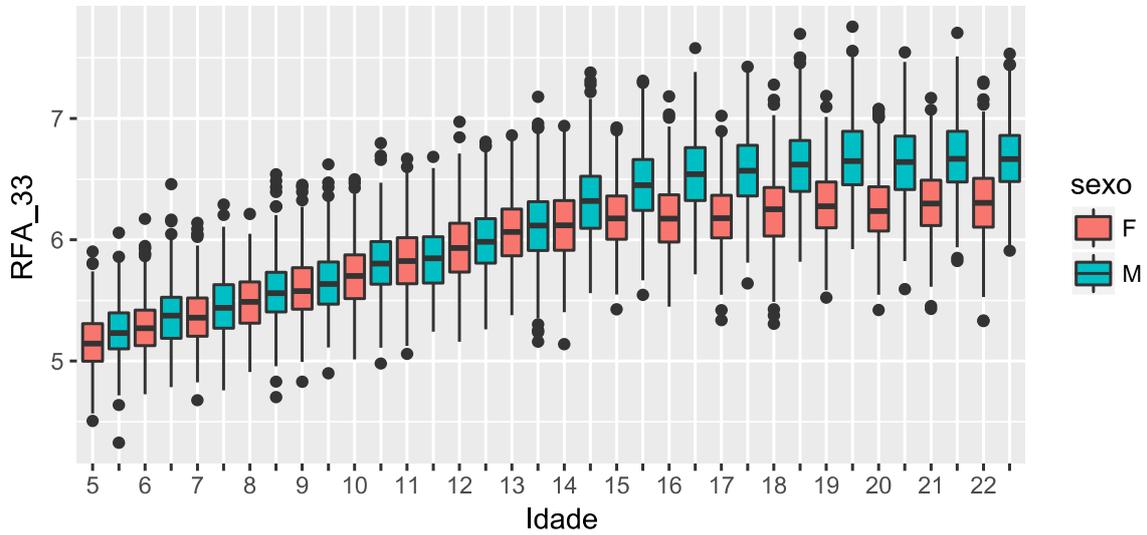
Distribuições da RFA_32 por Sexo e Idade

idades de 5 até 22 anos



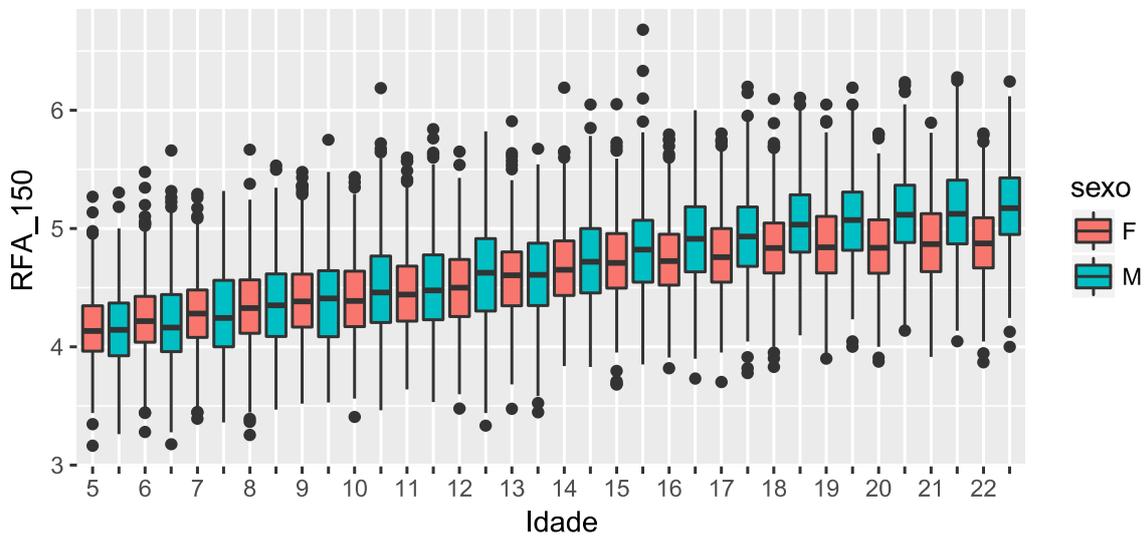
Distribuições da RFA_33 por Sexo e Idade

idades de 5 até 22 anos



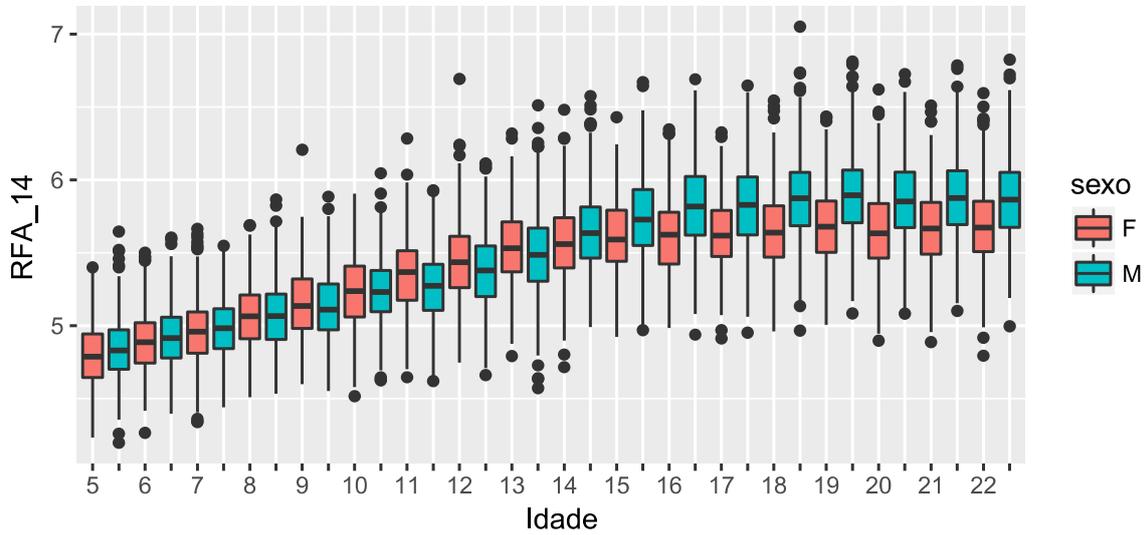
Distribuições da RFA_150 por Sexo e Idade

idades de 5 até 22 anos



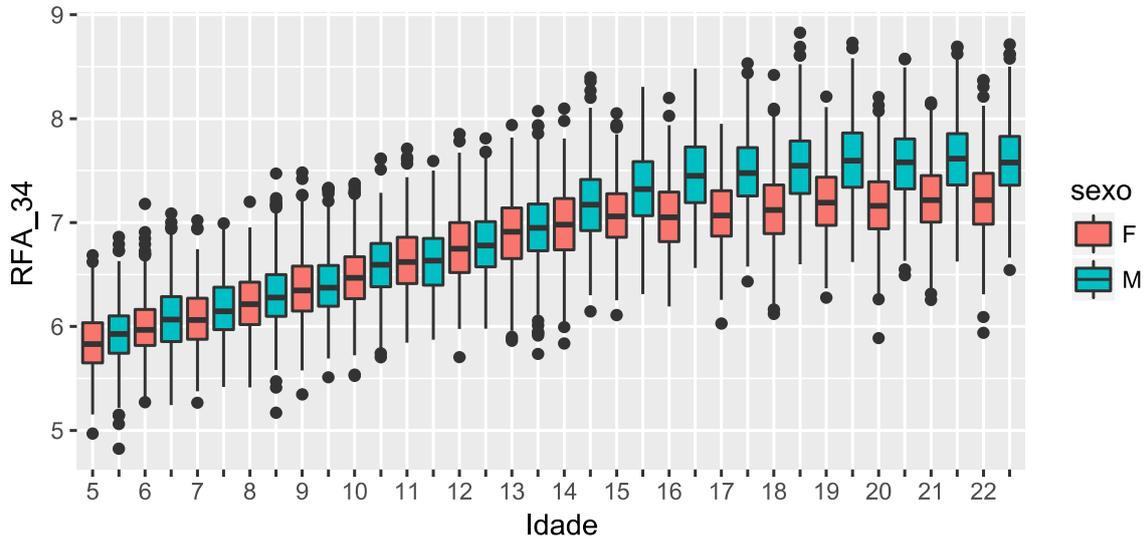
Distribuições da RFA_14 por Sexo e Idade

idades de 5 até 22 anos



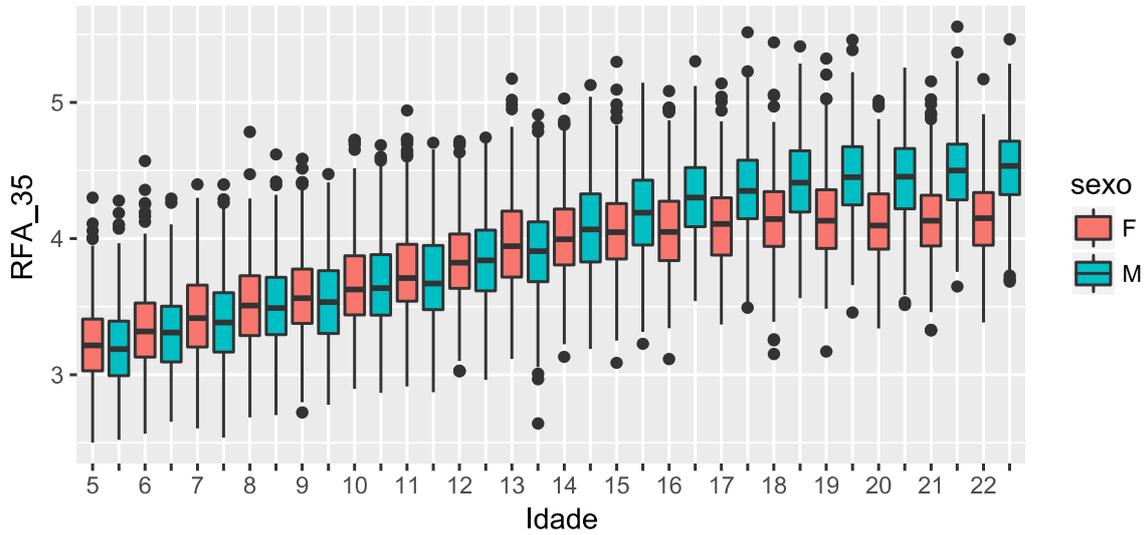
Distribuições da RFA_34 por Sexo e Idade

idades de 5 até 22 anos



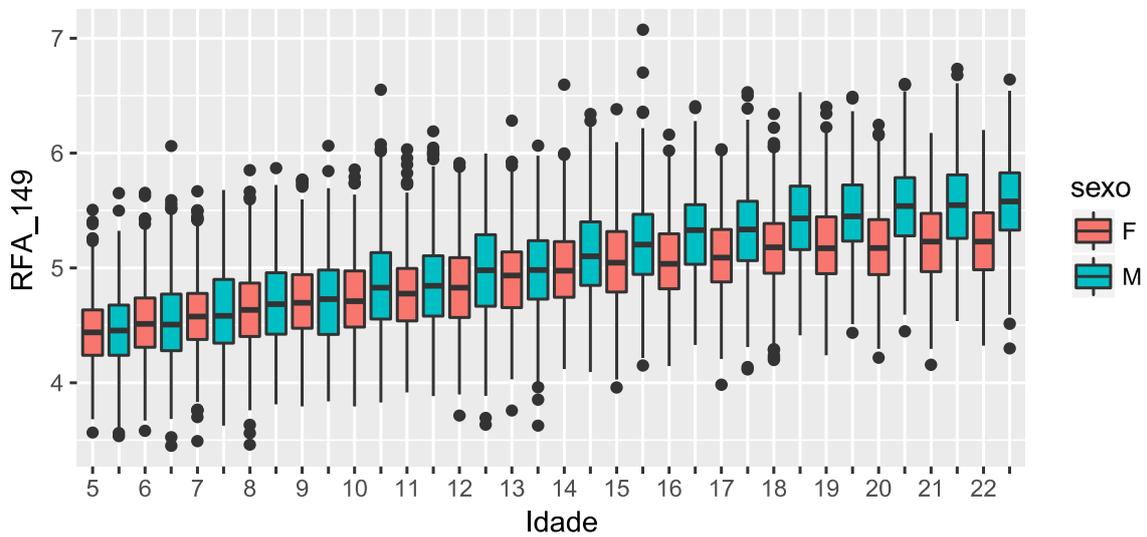
Distribuições da RFA_35 por Sexo e Idade

idades de 5 até 22 anos



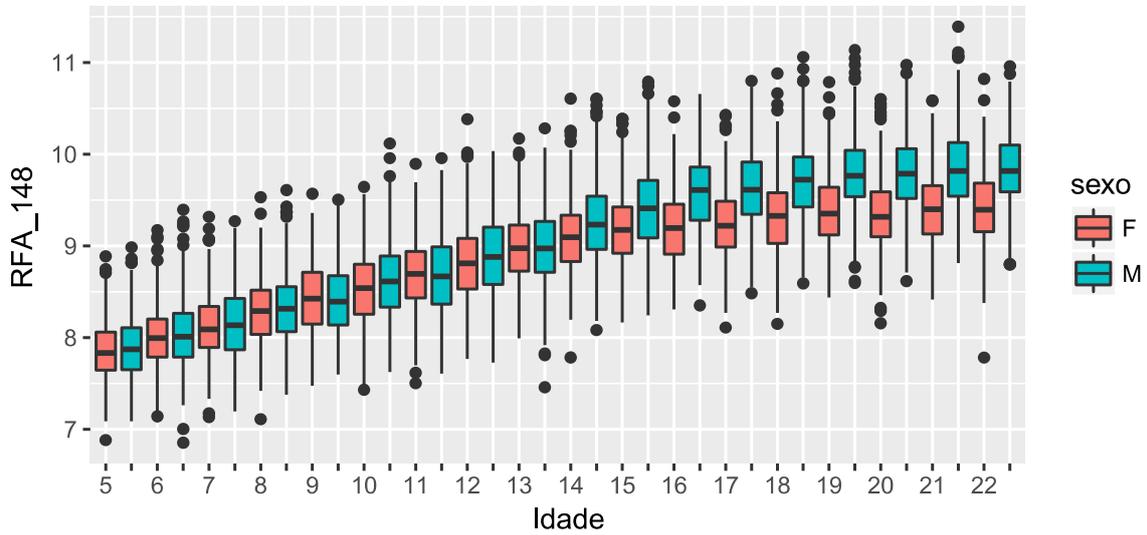
Distribuições da RFA_149 por Sexo e Idade

idades de 5 até 22 anos



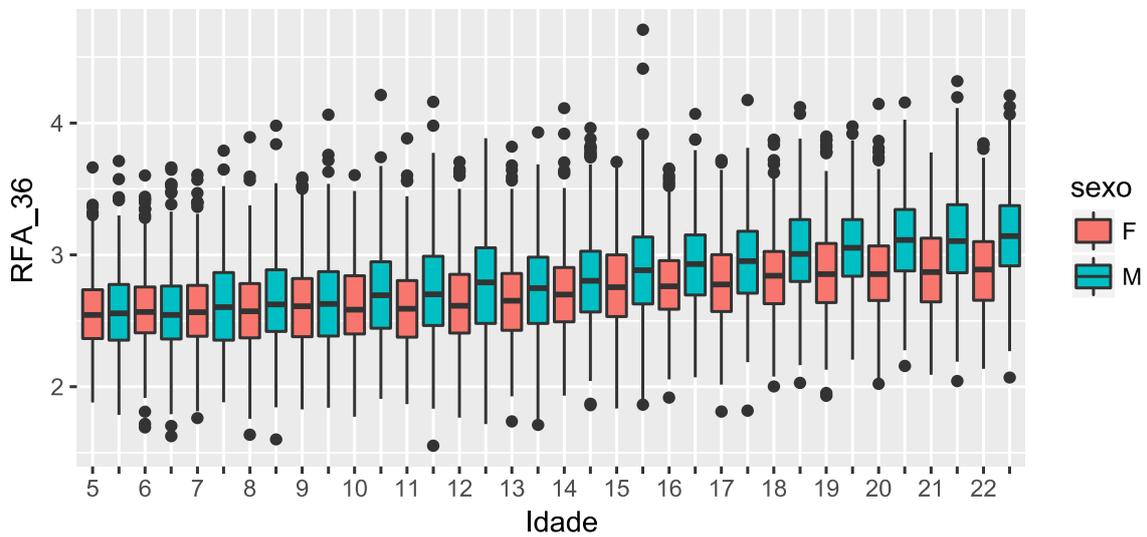
Distribuições da RFA_148 por Sexo e Idade

idades de 5 até 22 anos



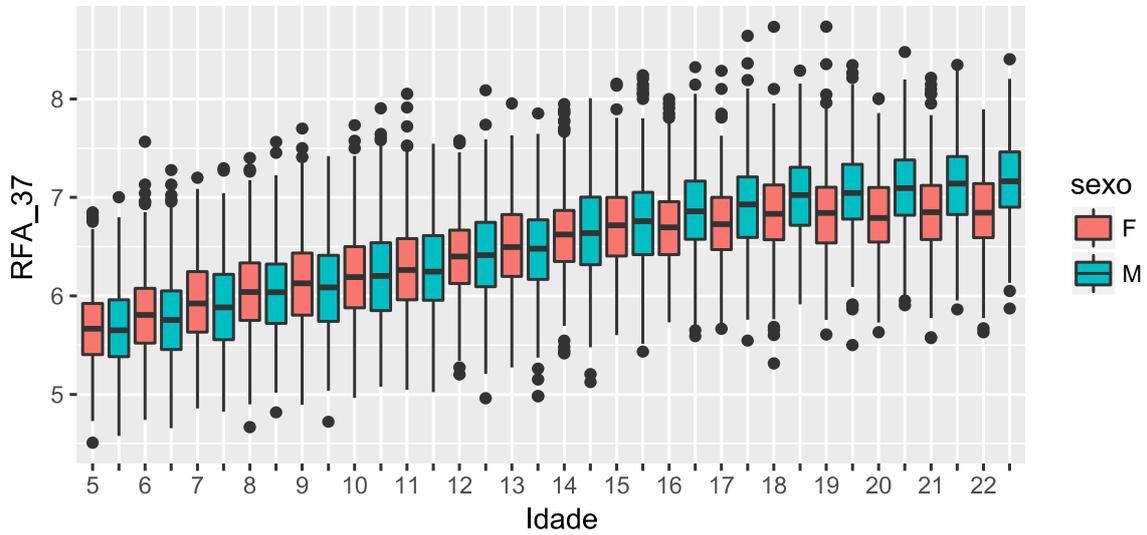
Distribuições da RFA_36 por Sexo e Idade

idades de 5 até 22 anos



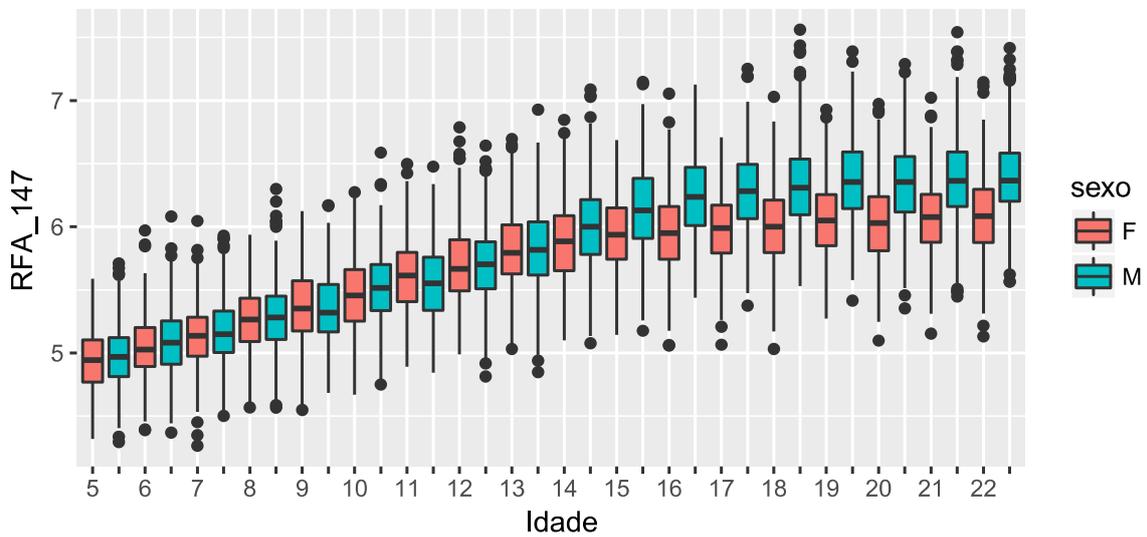
Distribuições da RFA_37 por Sexo e Idade

idades de 5 até 22 anos



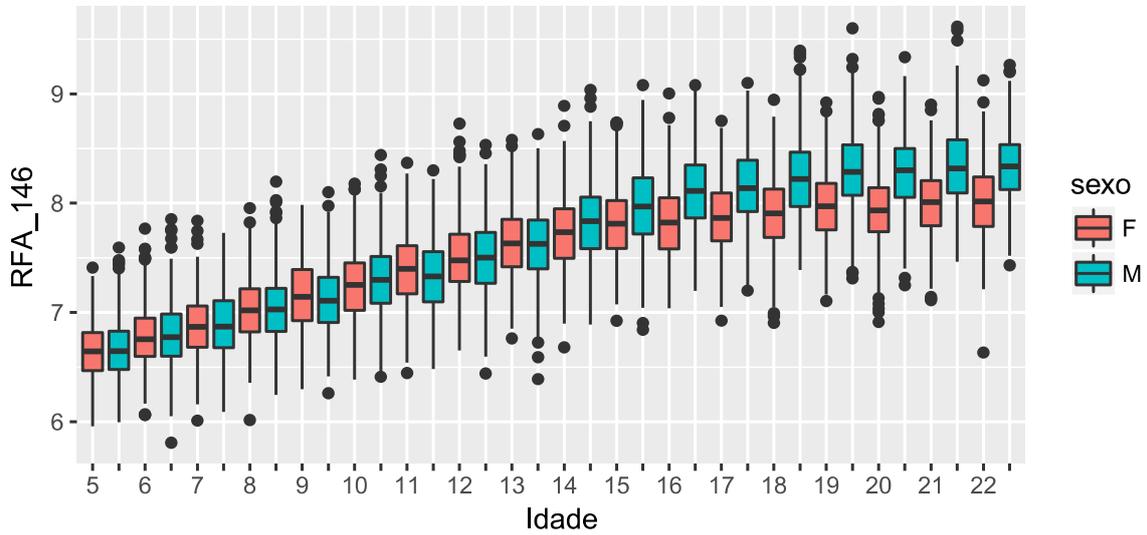
Distribuições da RFA_147 por Sexo e Idade

idades de 5 até 22 anos



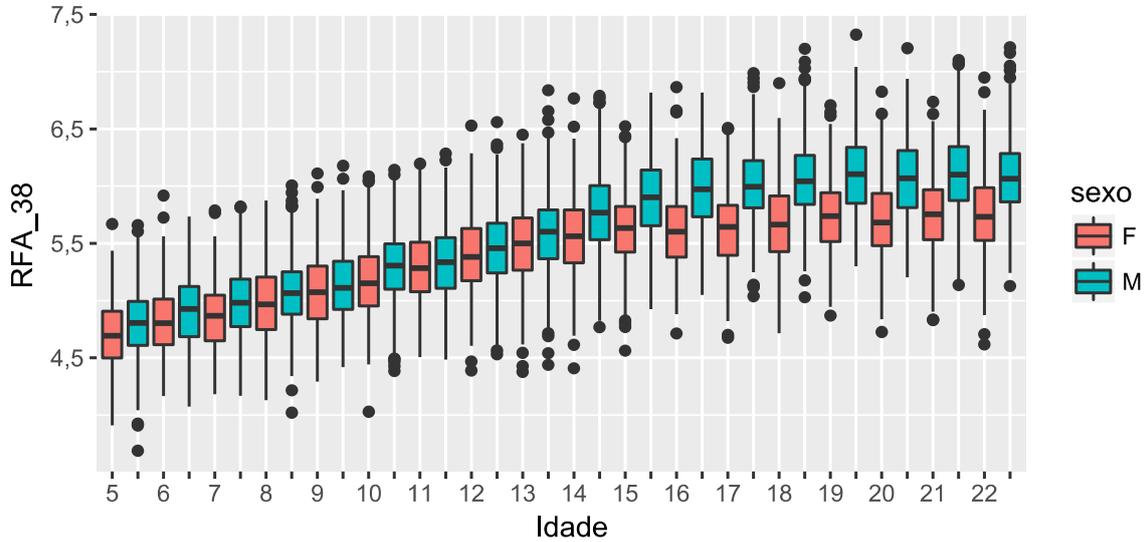
Distribuições da RFA_146 por Sexo e Idade

idades de 5 até 22 anos



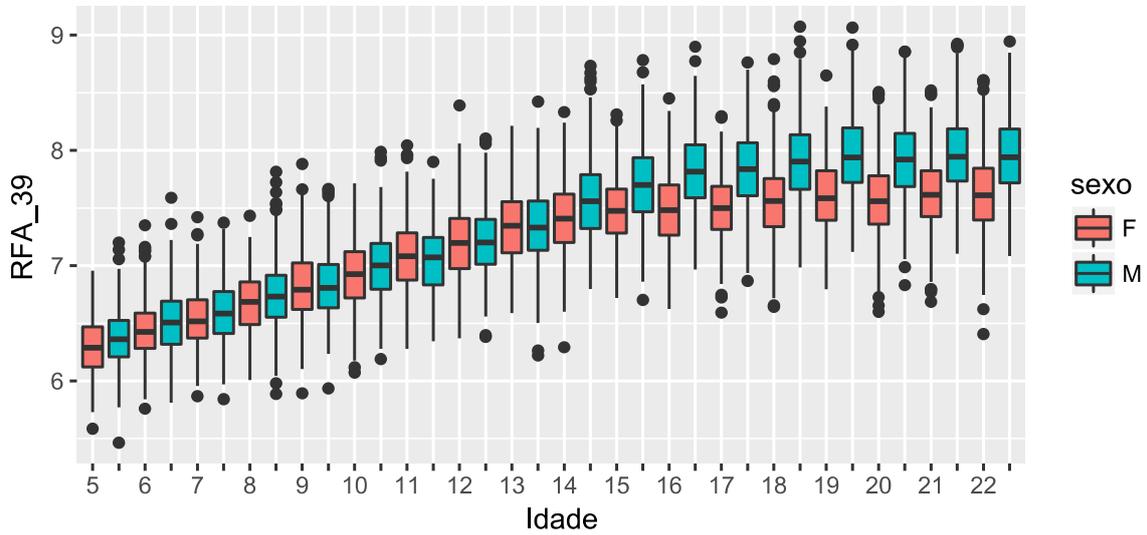
Distribuições da RFA_38 por Sexo e Idade

idades de 5 até 22 anos



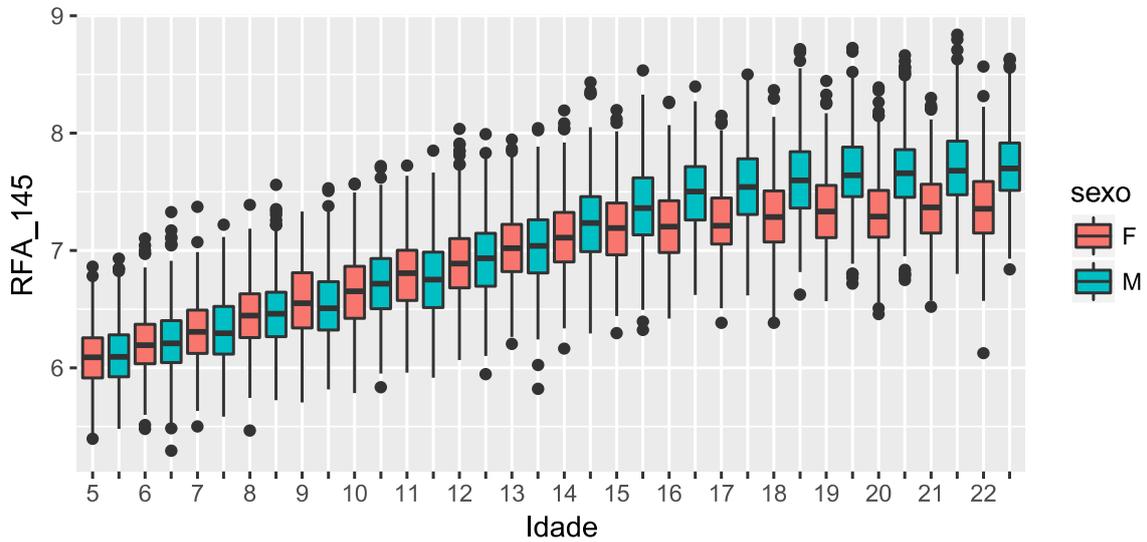
Distribuições da RFA_39 por Sexo e Idade

idades de 5 até 22 anos



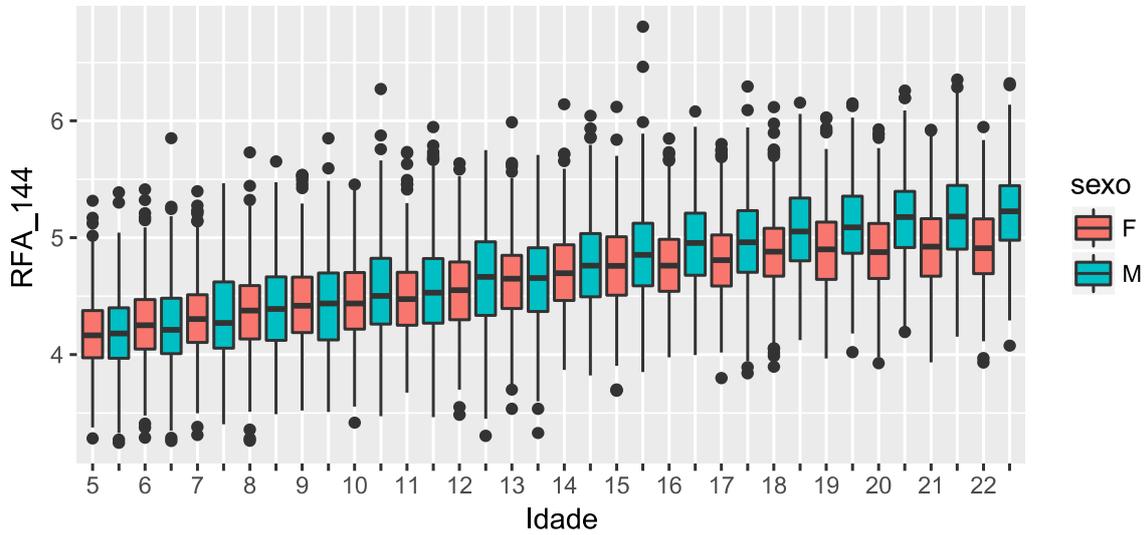
Distribuições da RFA_145 por Sexo e Idade

idades de 5 até 22 anos



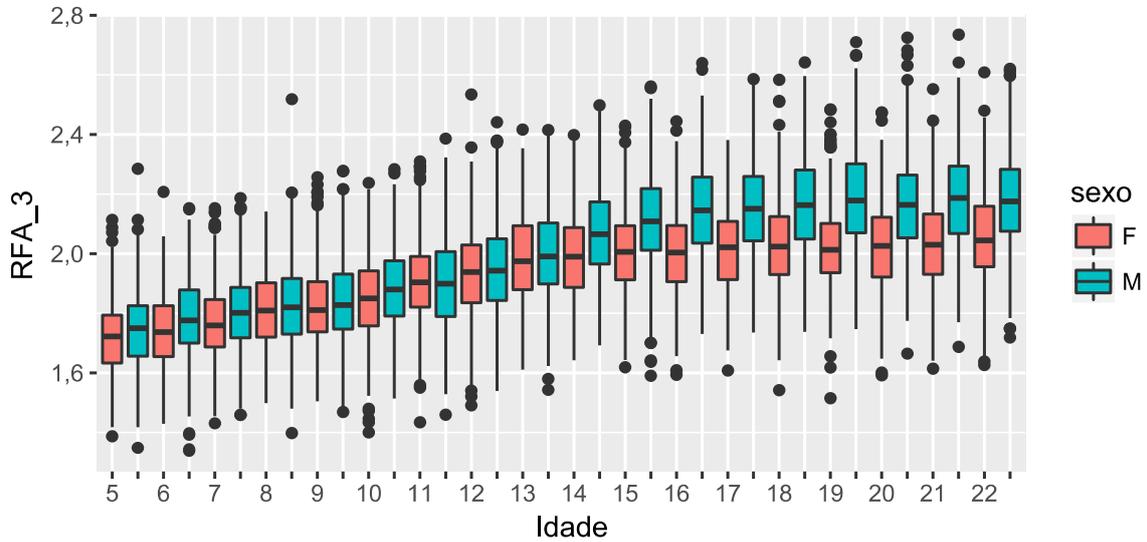
Distribuições da RFA_144 por Sexo e Idade

idades de 5 até 22 anos



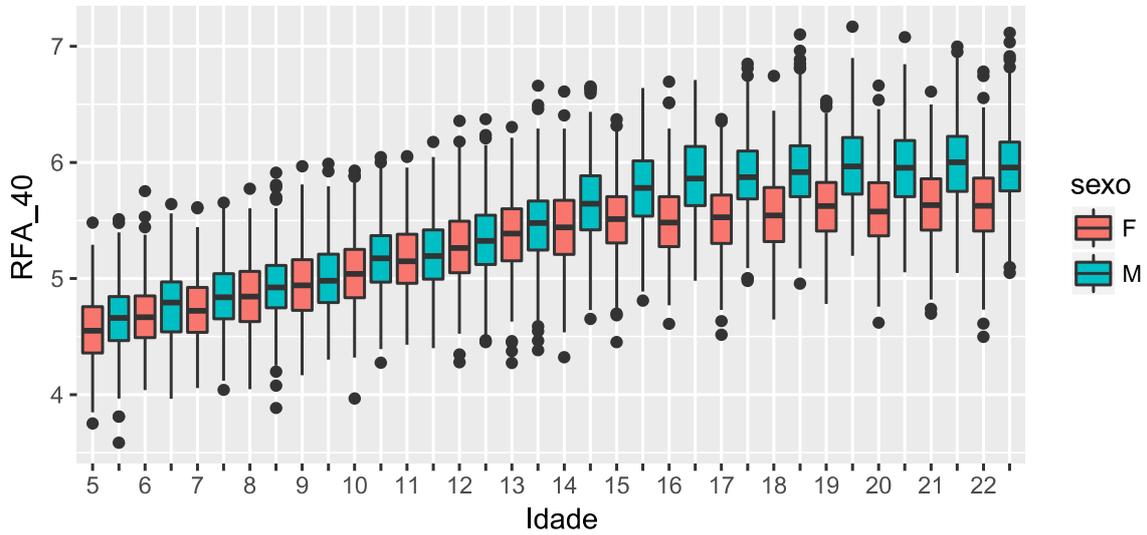
Distribuições da RFA_3 por Sexo e Idade

idades de 5 até 22 anos



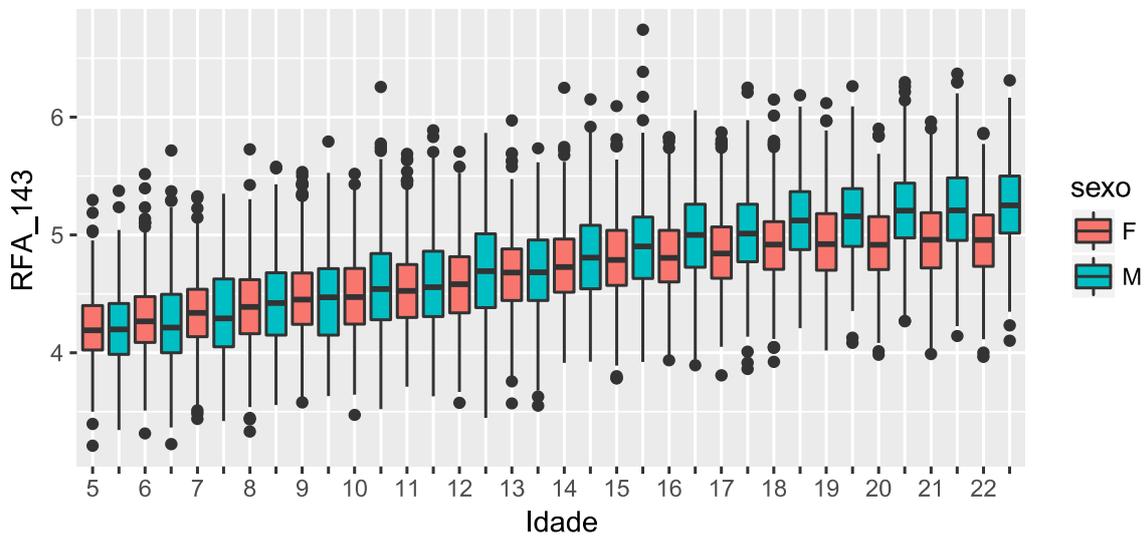
Distribuições da RFA_40 por Sexo e Idade

idades de 5 até 22 anos



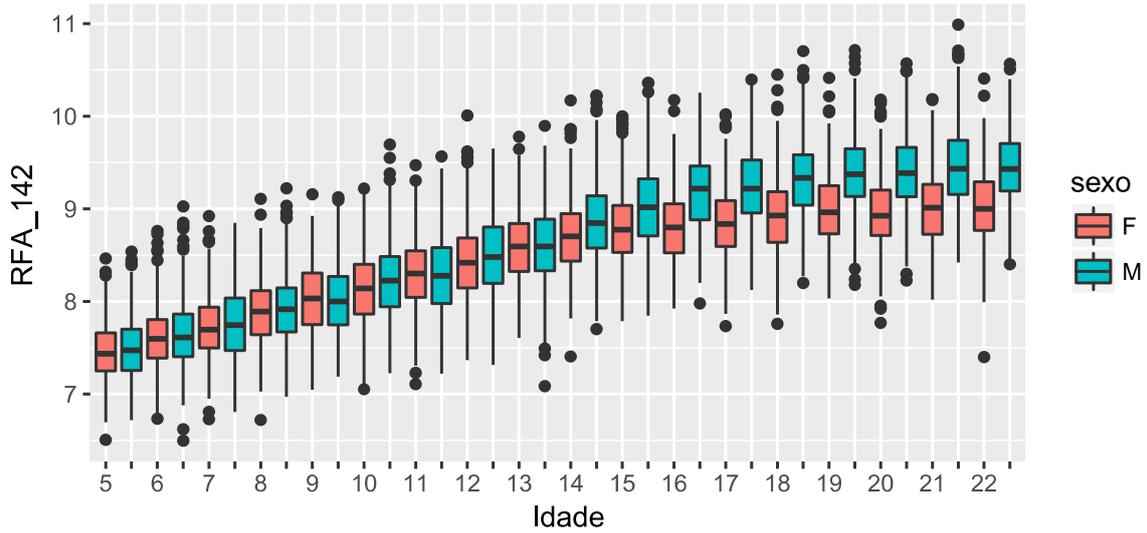
Distribuições da RFA_143 por Sexo e Idade

idades de 5 até 22 anos



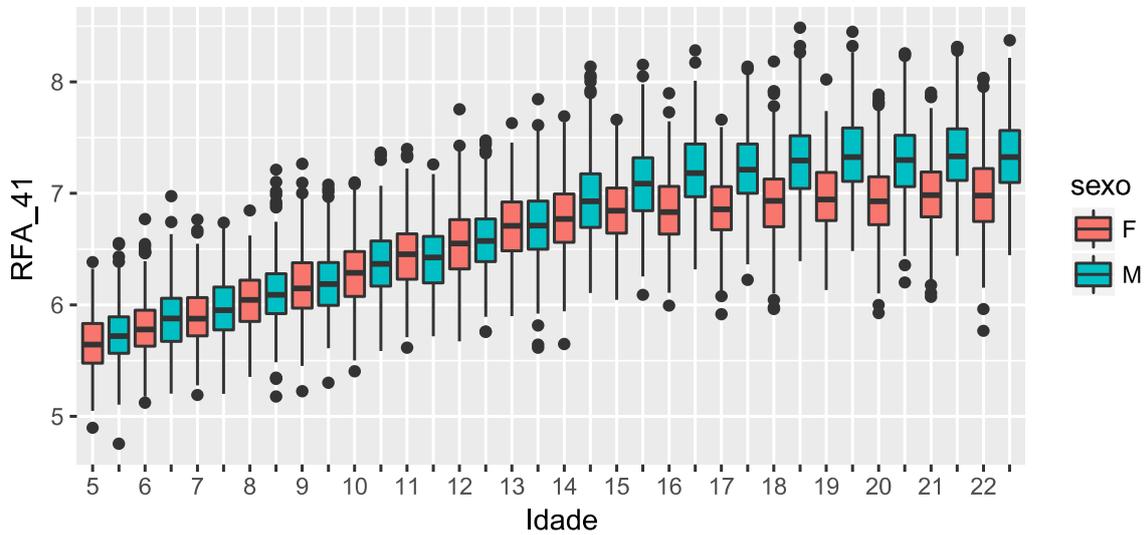
Distribuições da RFA_142 por Sexo e Idade

idades de 5 até 22 anos



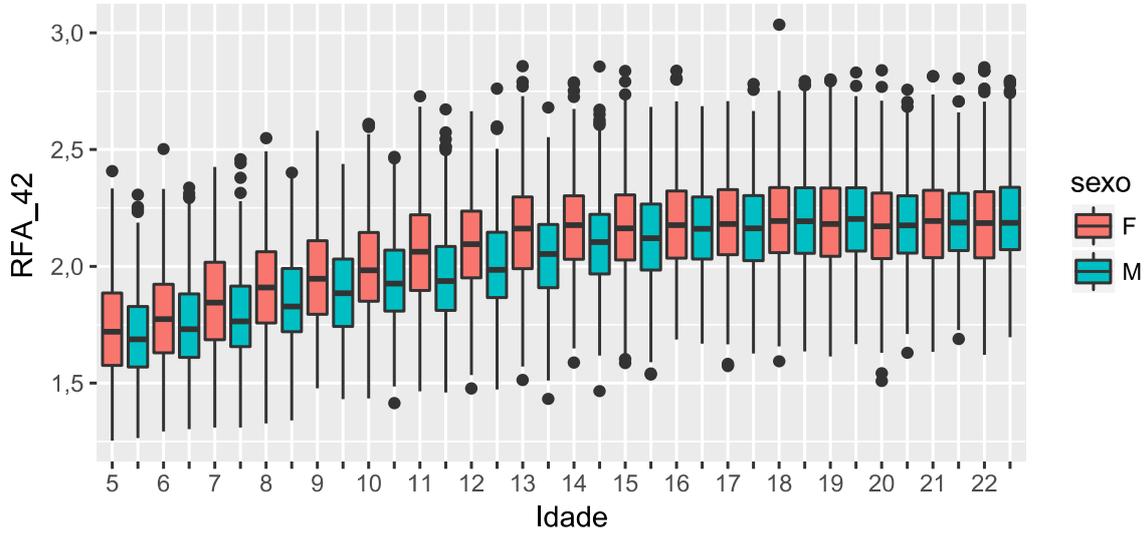
Distribuições da RFA_41 por Sexo e Idade

idades de 5 até 22 anos



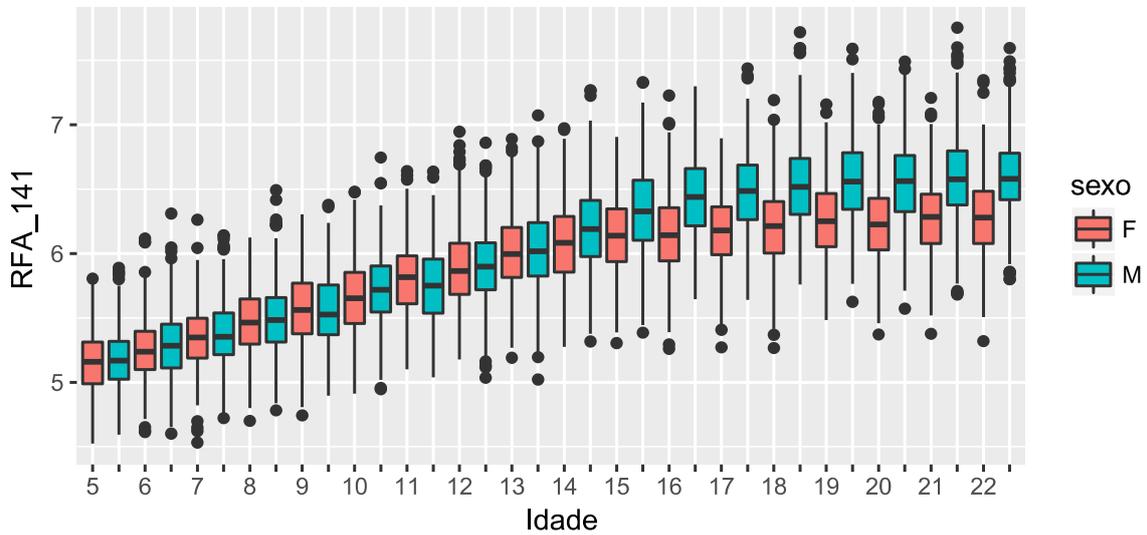
Distribuições da RFA_42 por Sexo e Idade

idades de 5 até 22 anos



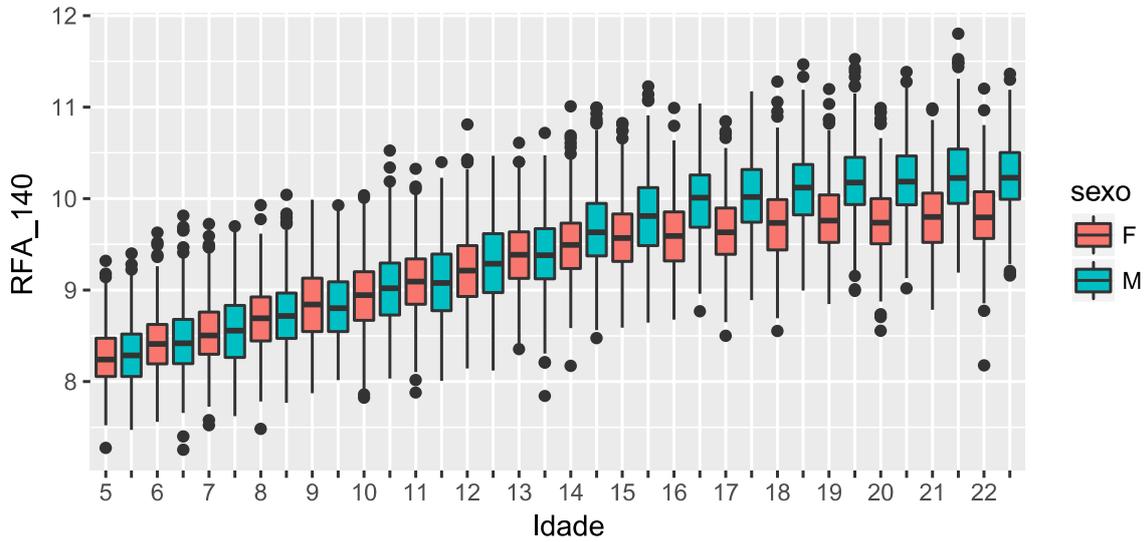
Distribuições da RFA_141 por Sexo e Idade

idades de 5 até 22 anos



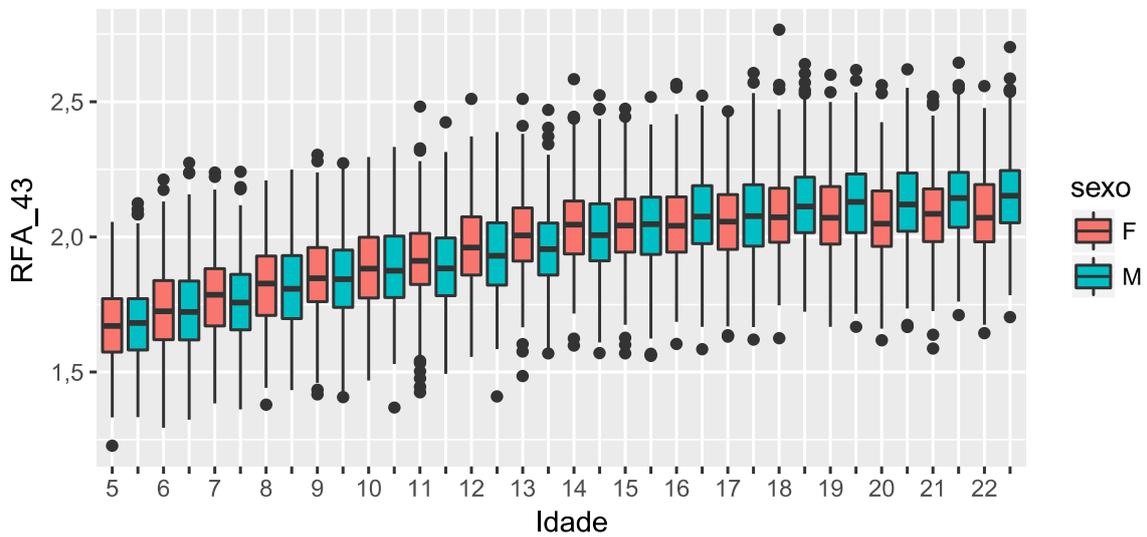
Distribuições da RFA_140 por Sexo e Idade

idades de 5 até 22 anos



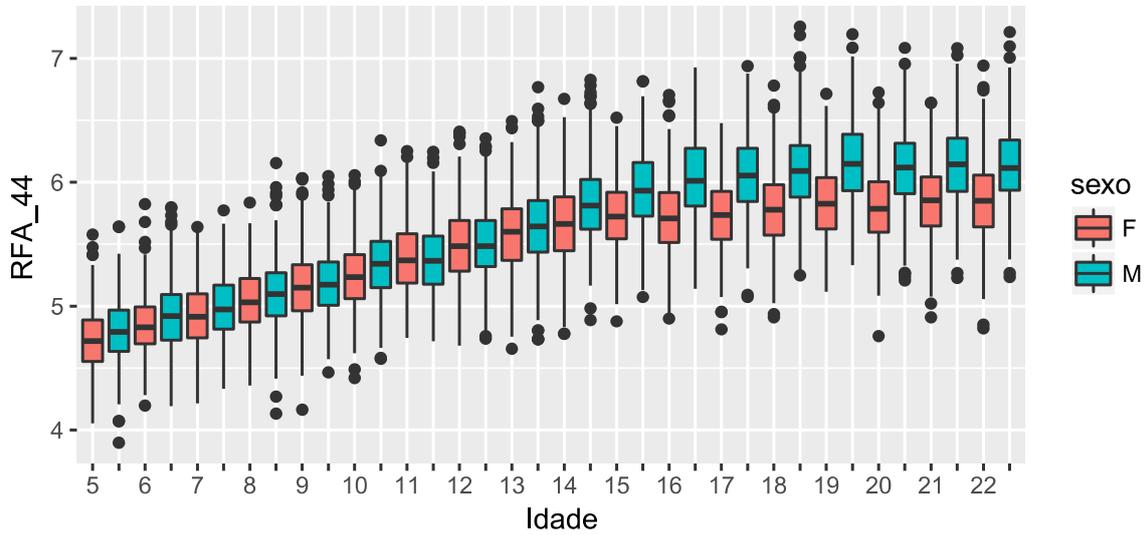
Distribuições da RFA_43 por Sexo e Idade

idades de 5 até 22 anos



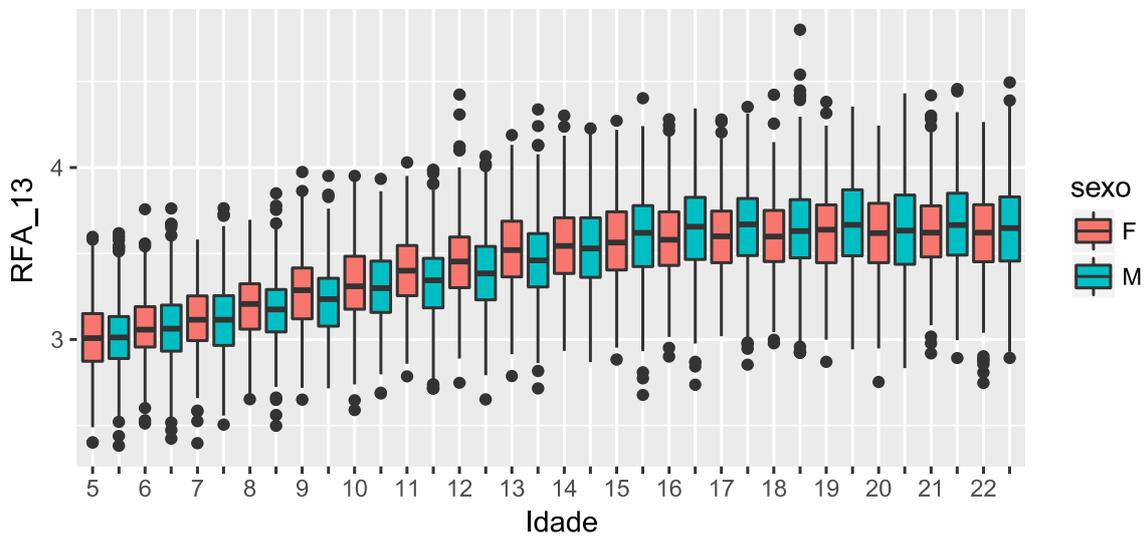
Distribuições da RFA_44 por Sexo e Idade

idades de 5 até 22 anos



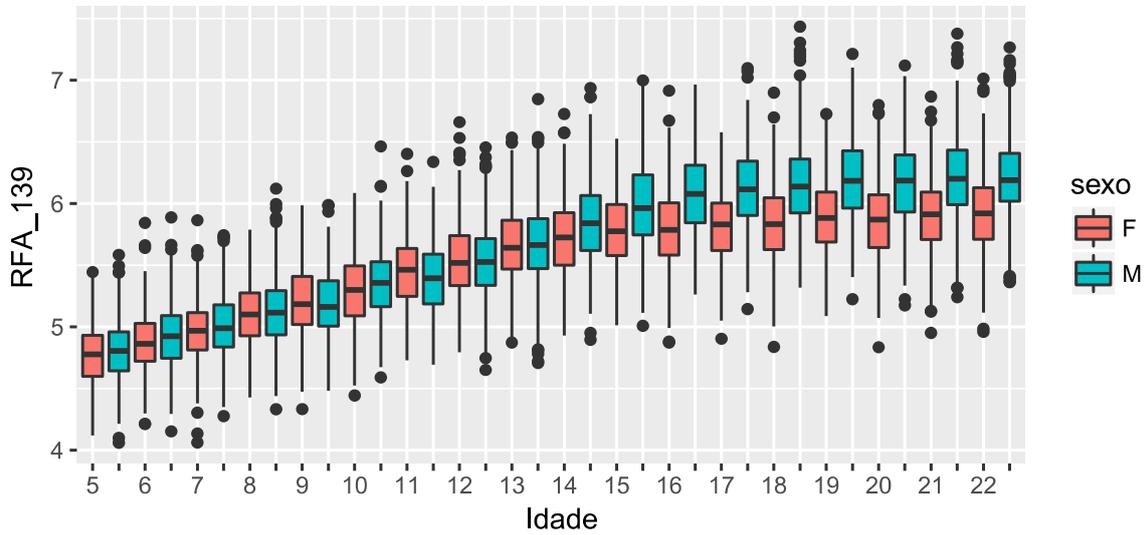
Distribuições da RFA_13 por Sexo e Idade

idades de 5 até 22 anos



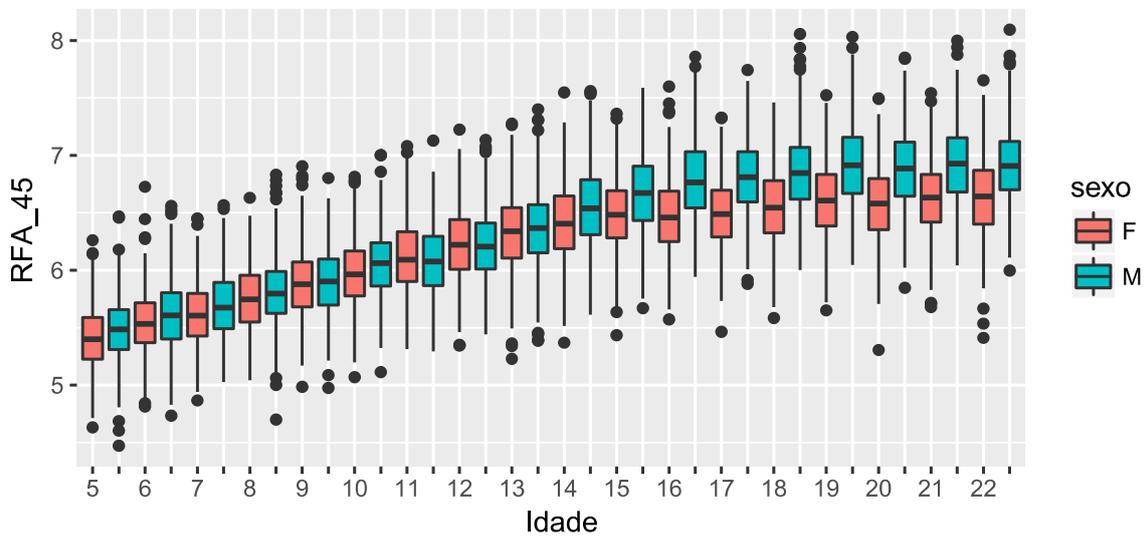
Distribuições da RFA_139 por Sexo e Idade

idades de 5 até 22 anos



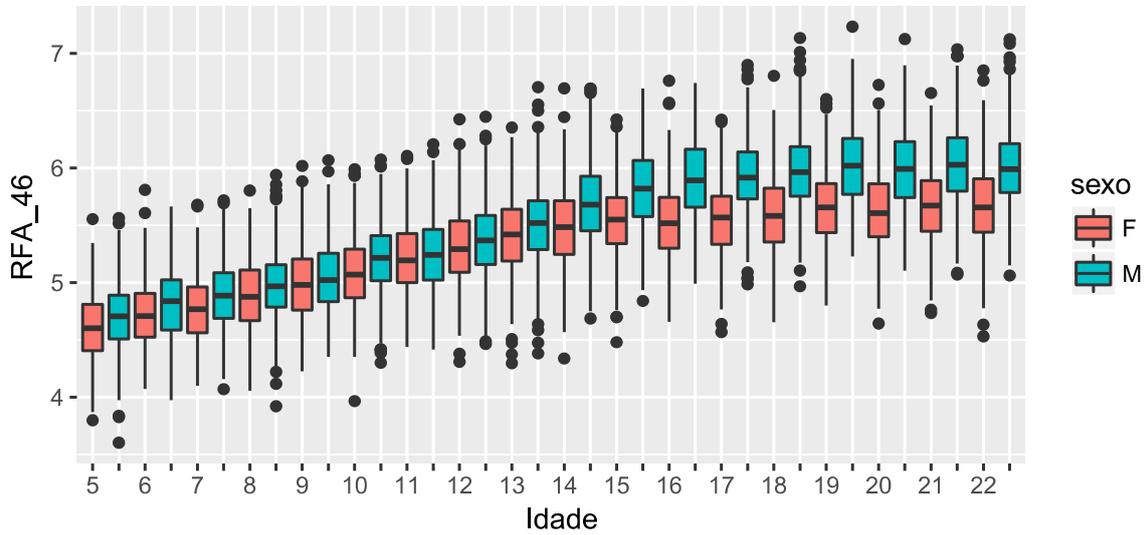
Distribuições da RFA_45 por Sexo e Idade

idades de 5 até 22 anos



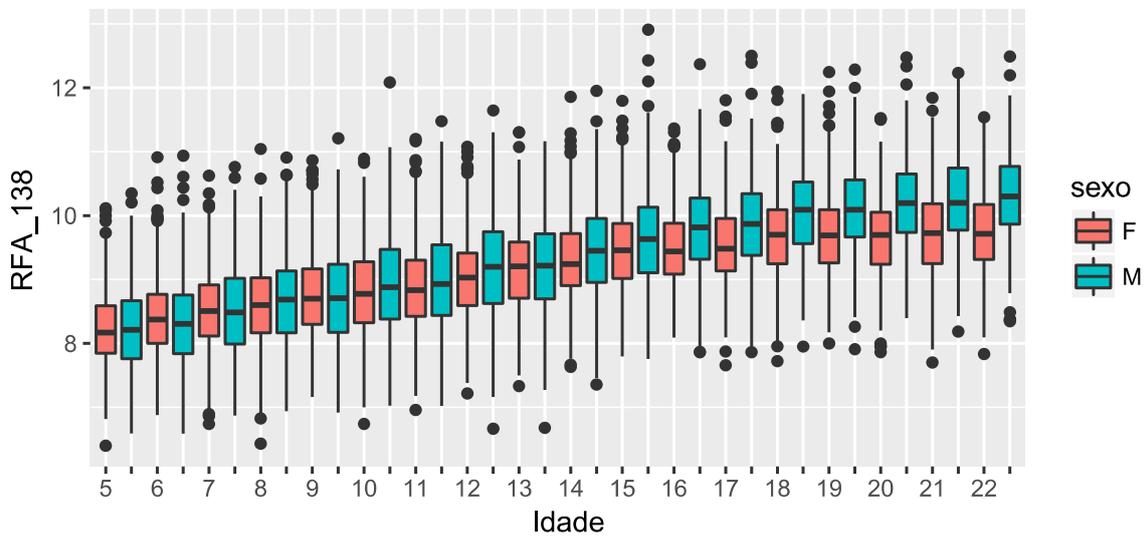
Distribuições da RFA_46 por Sexo e Idade

idades de 5 até 22 anos



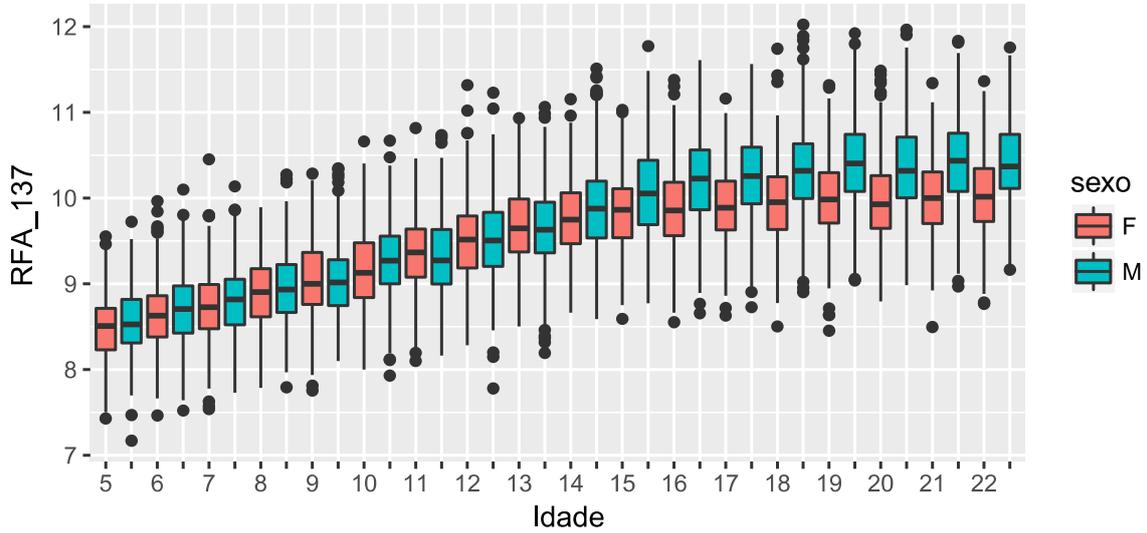
Distribuições da RFA_138 por Sexo e Idade

idades de 5 até 22 anos



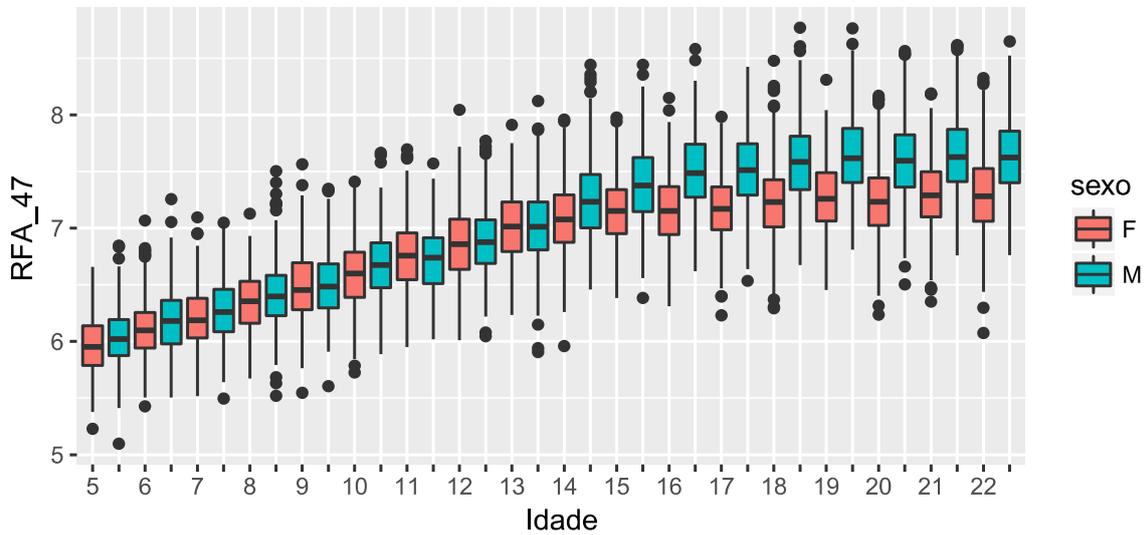
Distribuições da RFA_137 por Sexo e Idade

idades de 5 até 22 anos



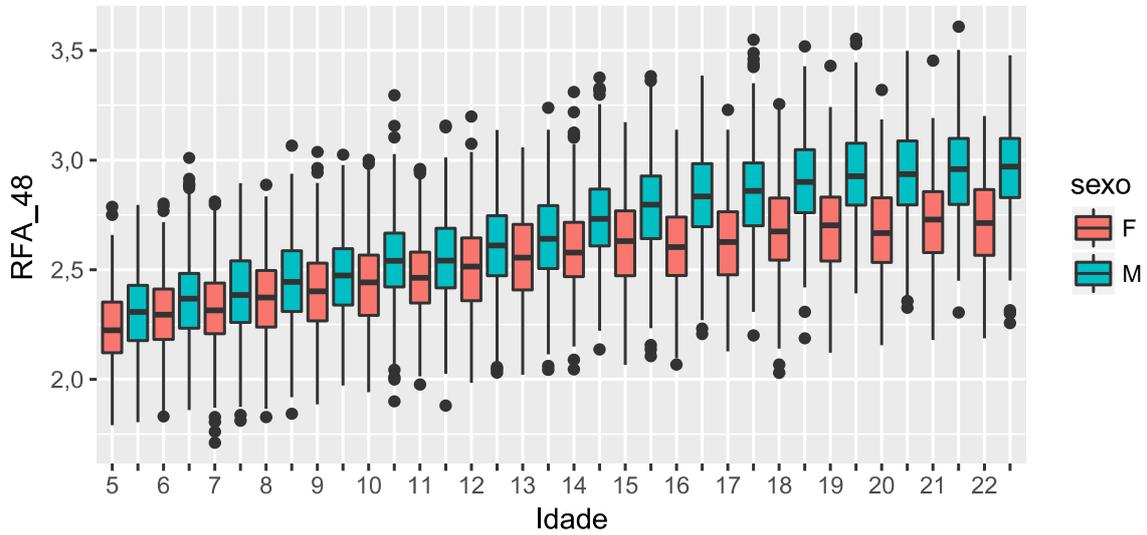
Distribuições da RFA_47 por Sexo e Idade

idades de 5 até 22 anos



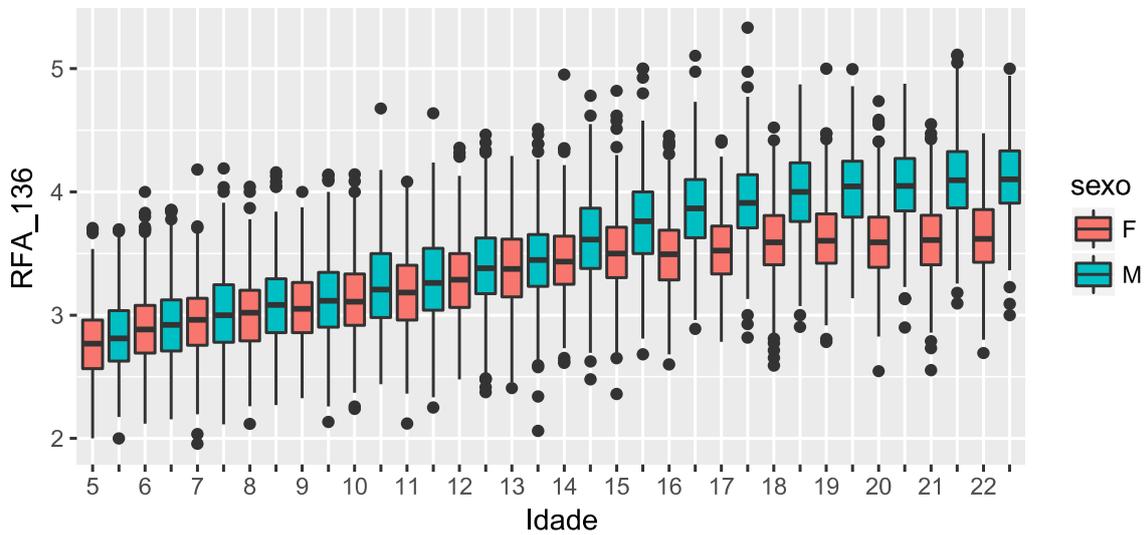
Distribuições da RFA_48 por Sexo e Idade

idades de 5 até 22 anos



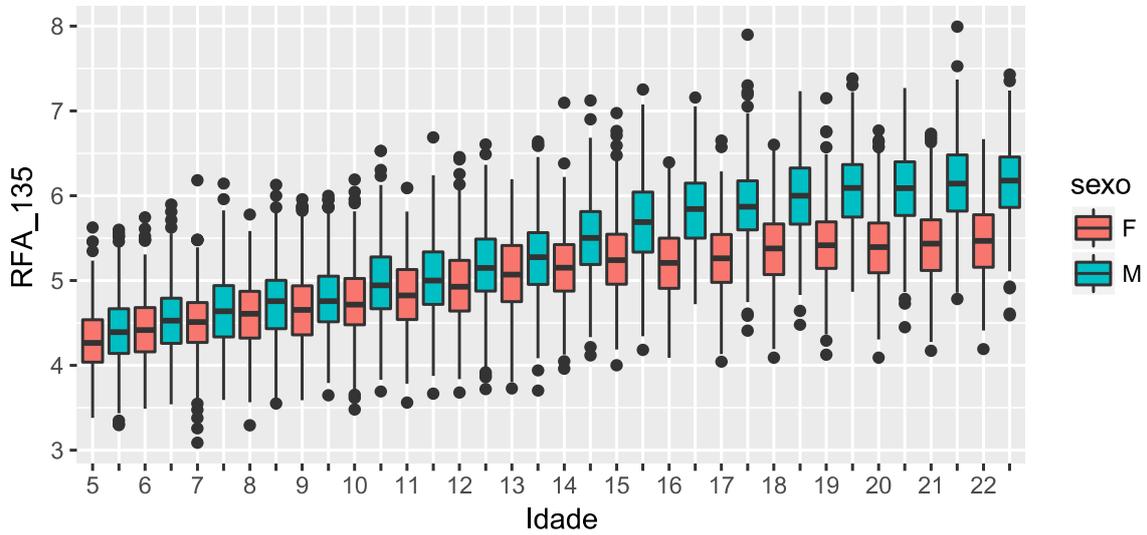
Distribuições da RFA_136 por Sexo e Idade

idades de 5 até 22 anos



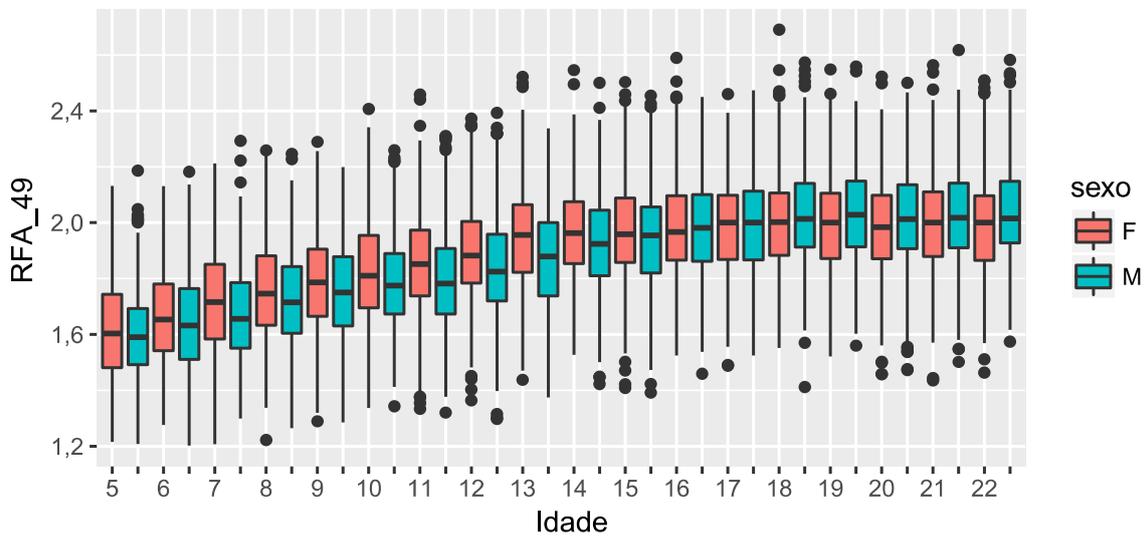
Distribuições da RFA_135 por Sexo e Idade

idades de 5 até 22 anos



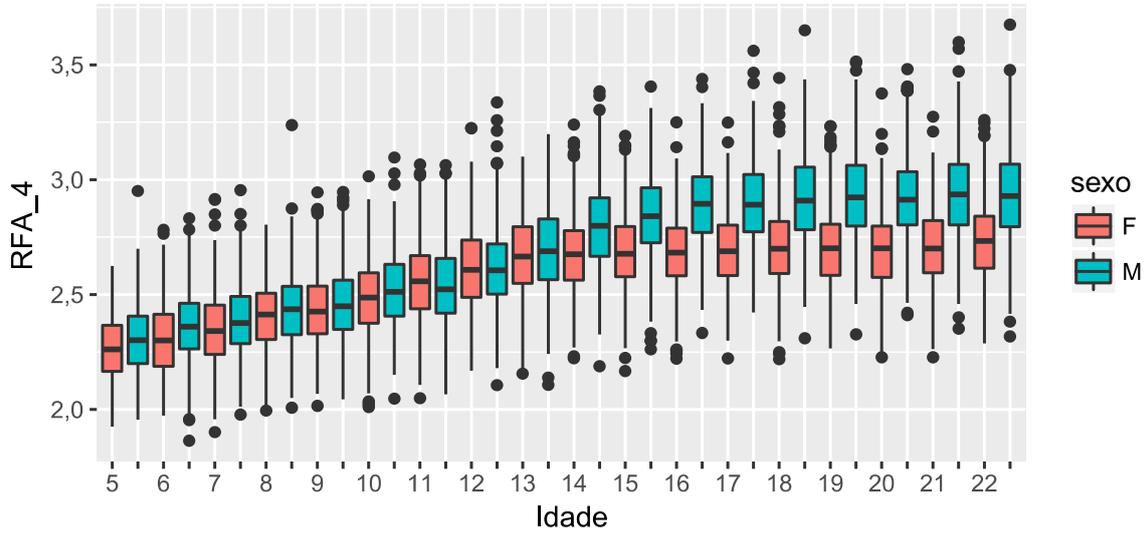
Distribuições da RFA_49 por Sexo e Idade

idades de 5 até 22 anos



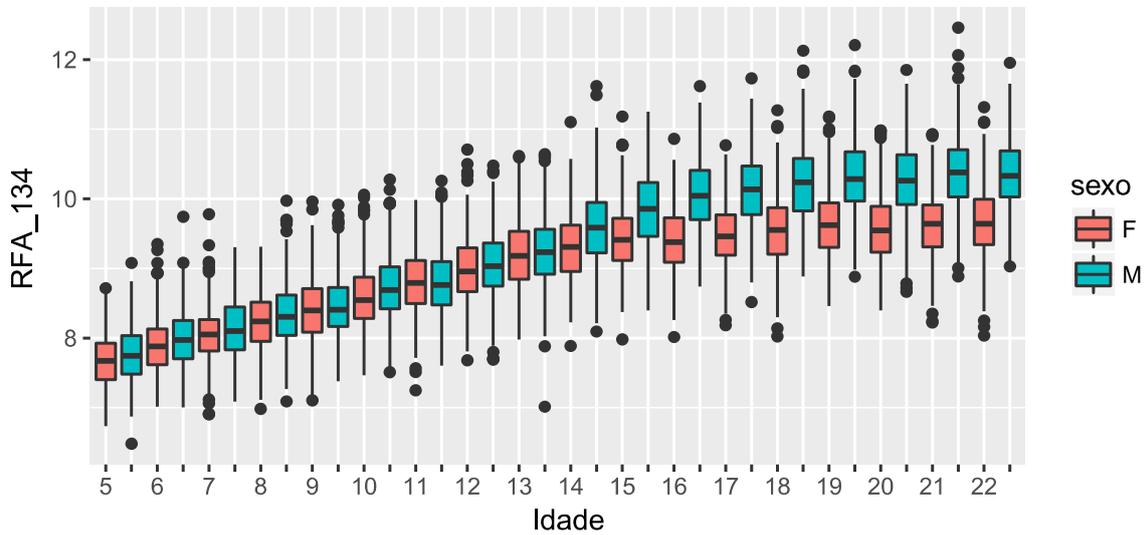
Distribuições da RFA_4 por Sexo e Idade

idades de 5 até 22 anos



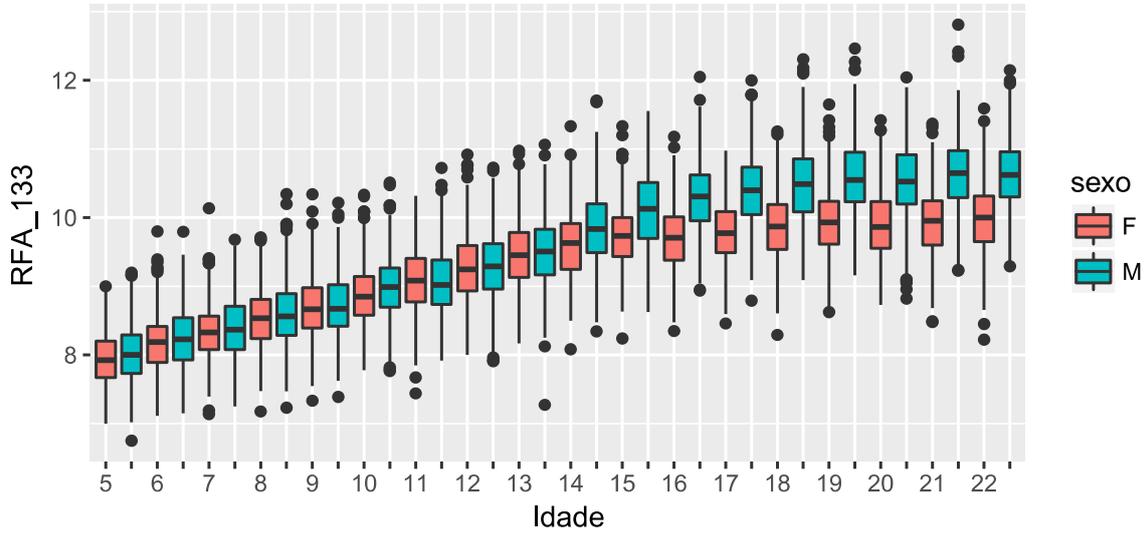
Distribuições da RFA_134 por Sexo e Idade

idades de 5 até 22 anos



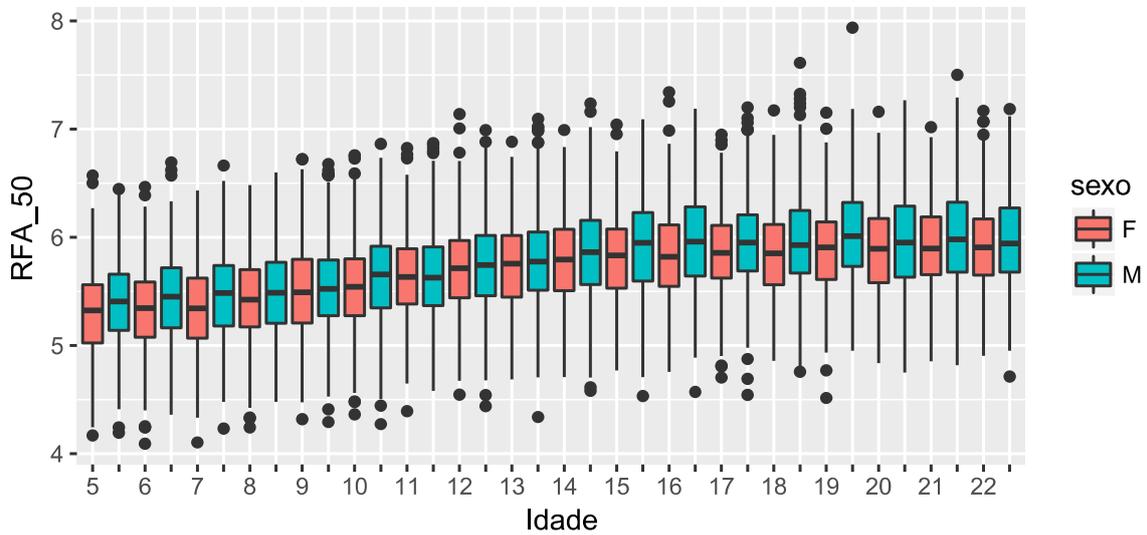
Distribuições da RFA_133 por Sexo e Idade

idades de 5 até 22 anos



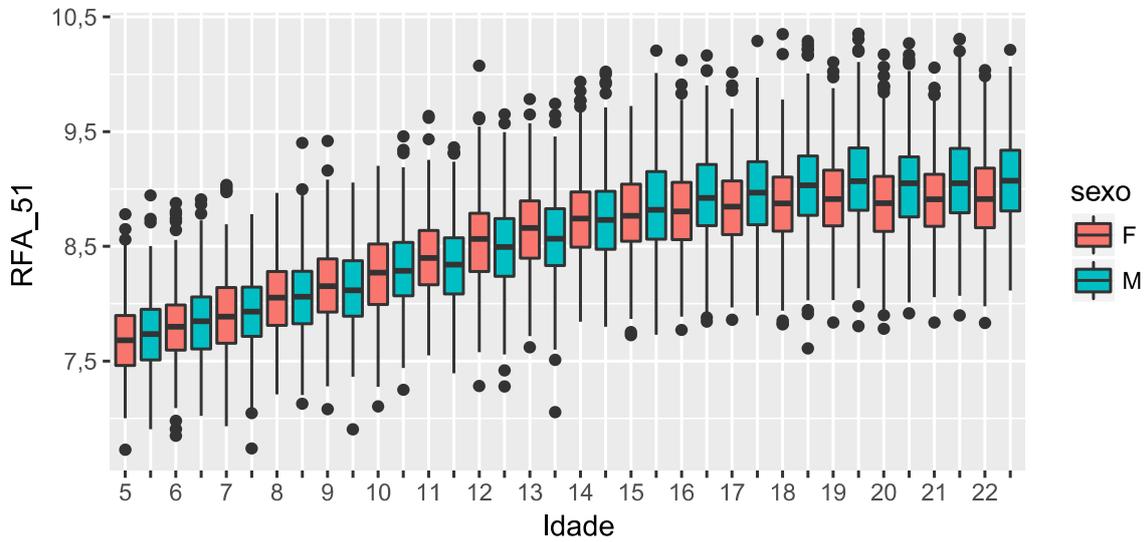
Distribuições da RFA_50 por Sexo e Idade

idades de 5 até 22 anos



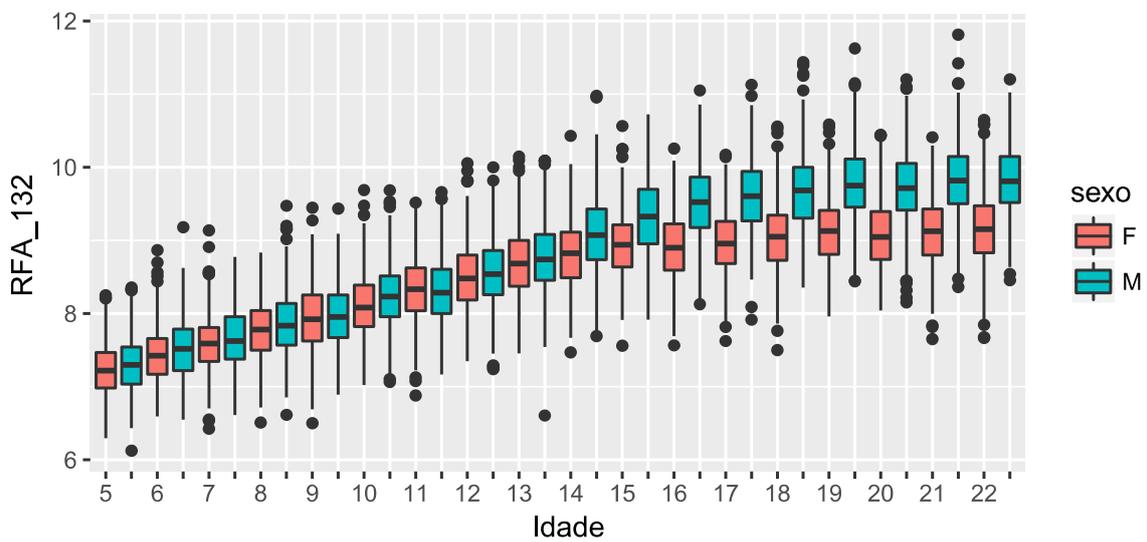
Distribuições da RFA_51 por Sexo e Idade

idades de 5 até 22 anos



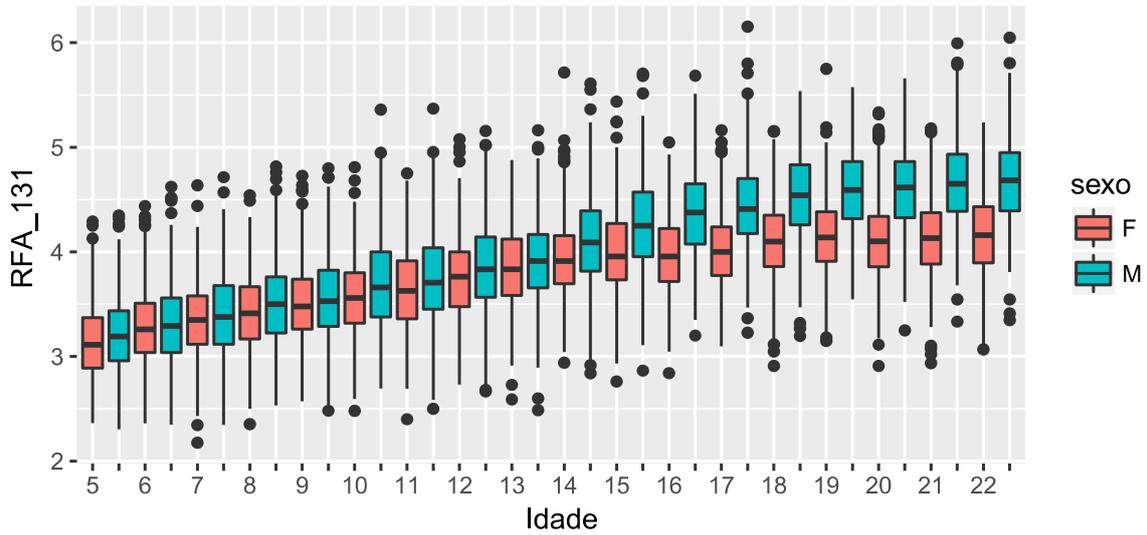
Distribuições da RFA_132 por Sexo e Idade

idades de 5 até 22 anos



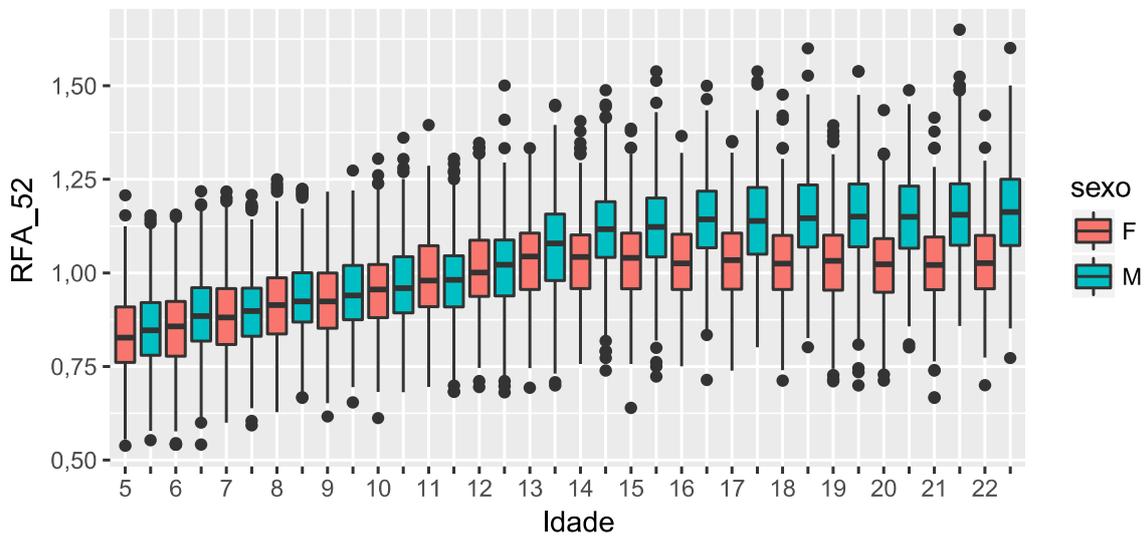
Distribuições da RFA_131 por Sexo e Idade

idades de 5 até 22 anos



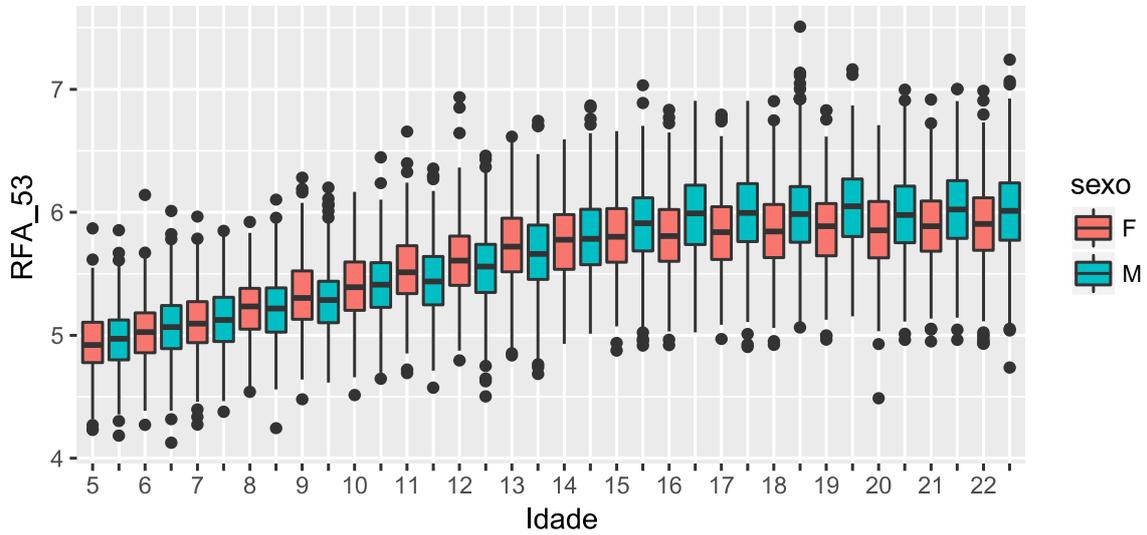
Distribuições da RFA_52 por Sexo e Idade

idades de 5 até 22 anos



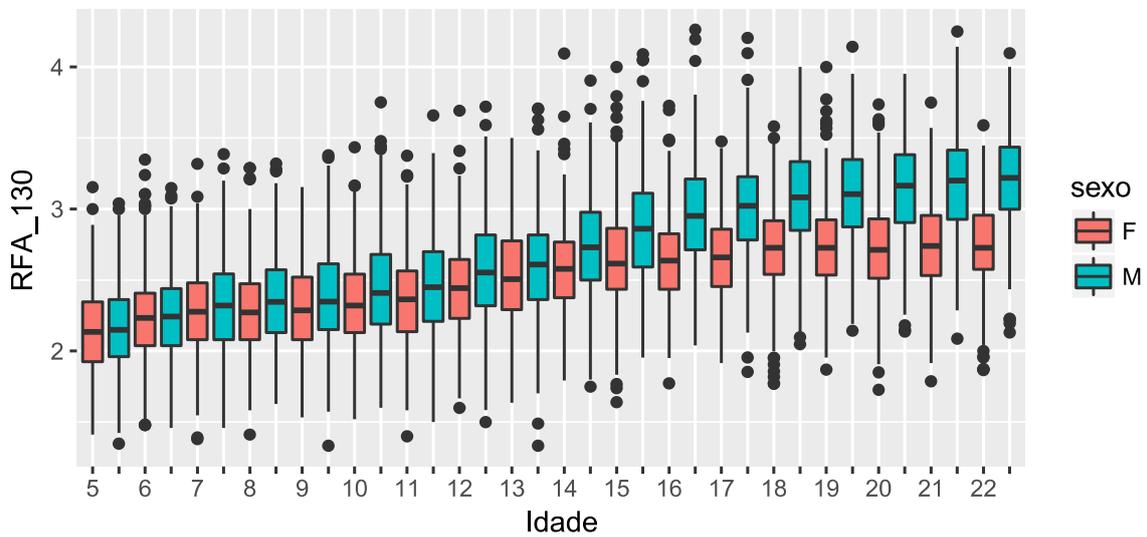
Distribuições da RFA_53 por Sexo e Idade

idades de 5 até 22 anos



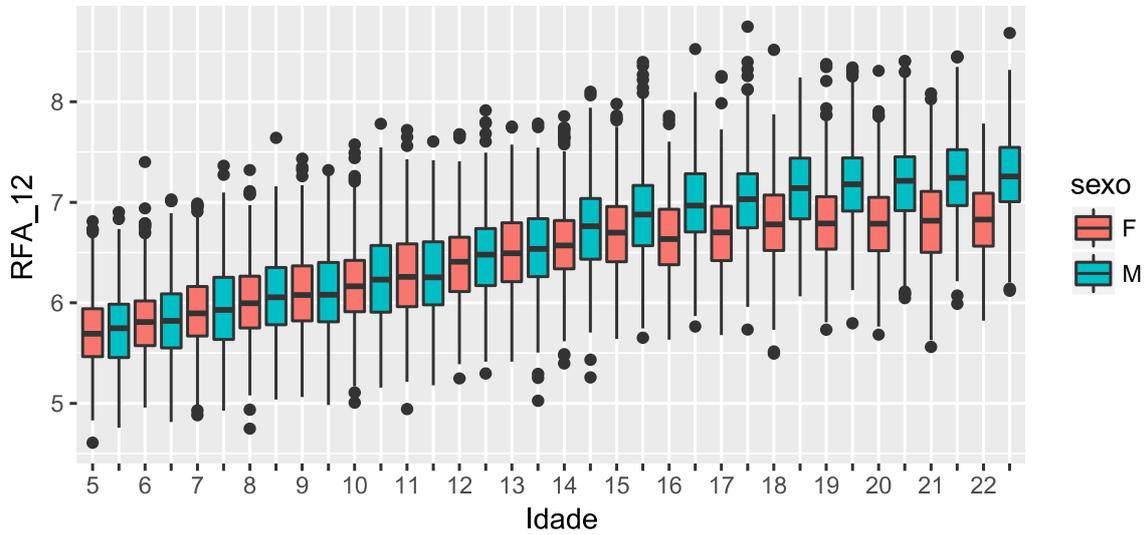
Distribuições da RFA_130 por Sexo e Idade

idades de 5 até 22 anos



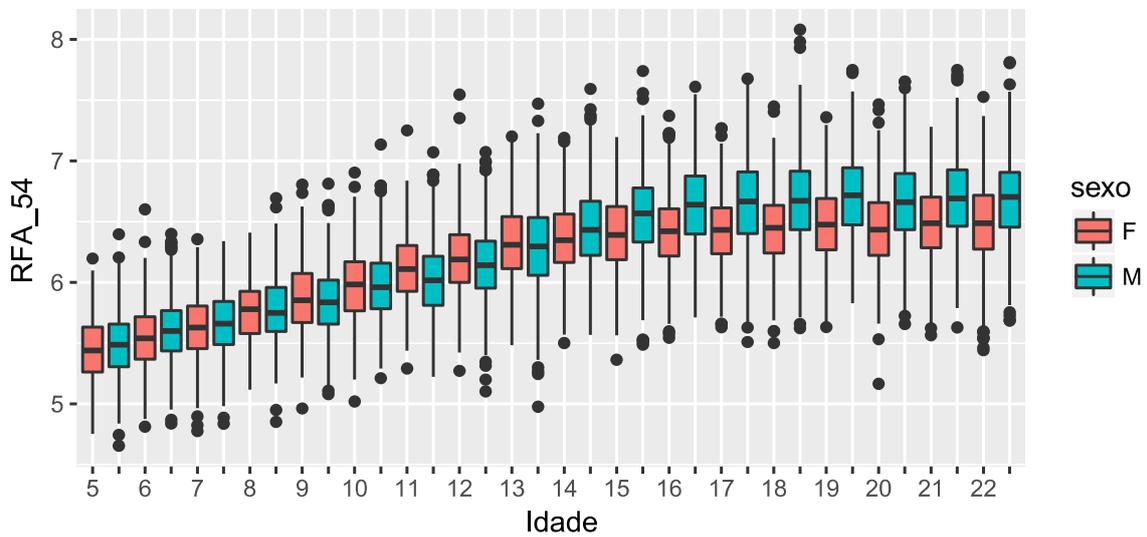
Distribuições da RFA_12 por Sexo e Idade

idades de 5 até 22 anos



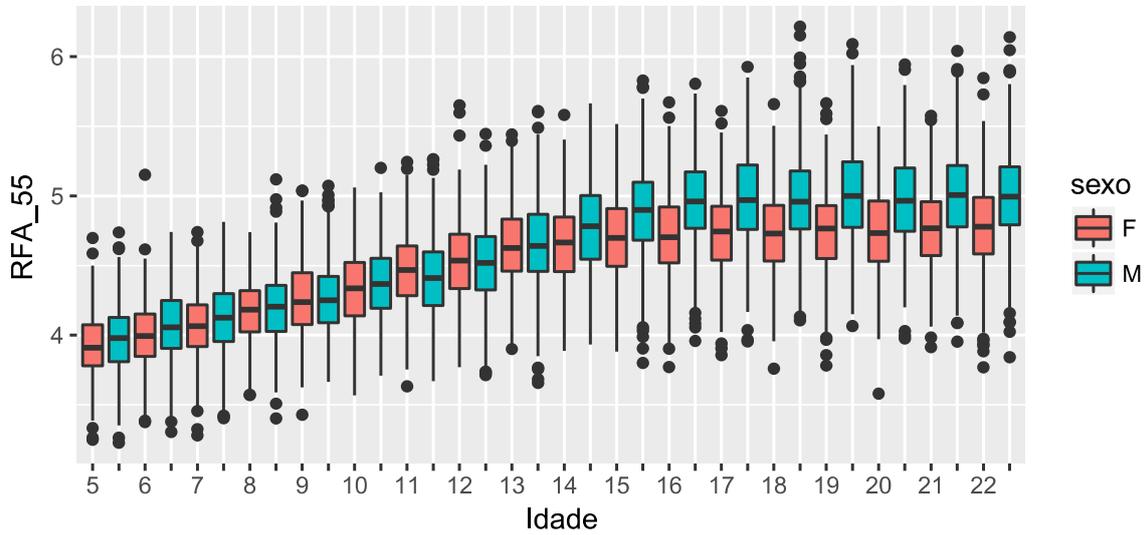
Distribuições da RFA_54 por Sexo e Idade

idades de 5 até 22 anos



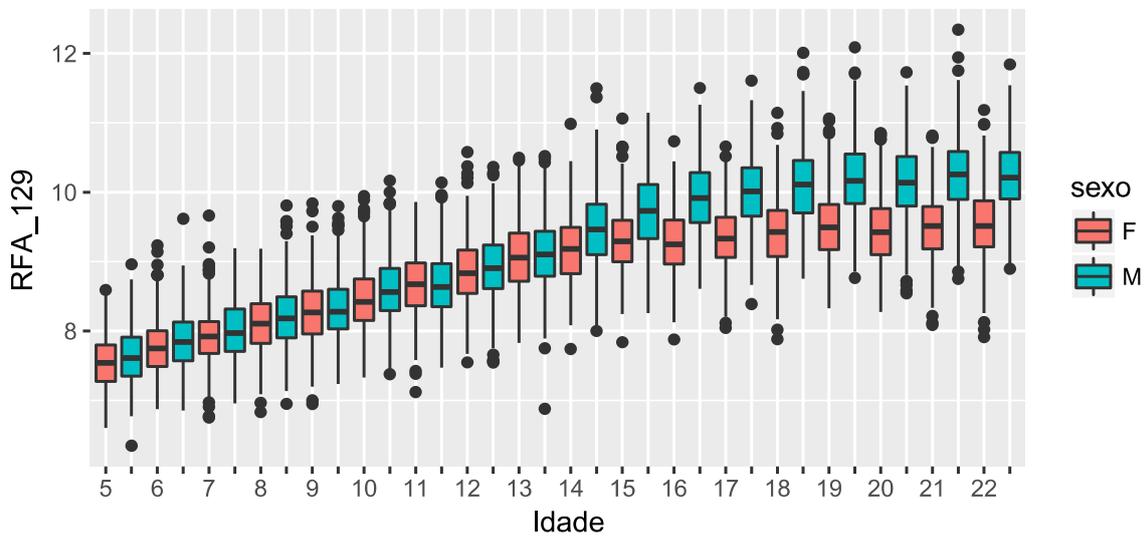
Distribuições da RFA_55 por Sexo e Idade

idades de 5 até 22 anos



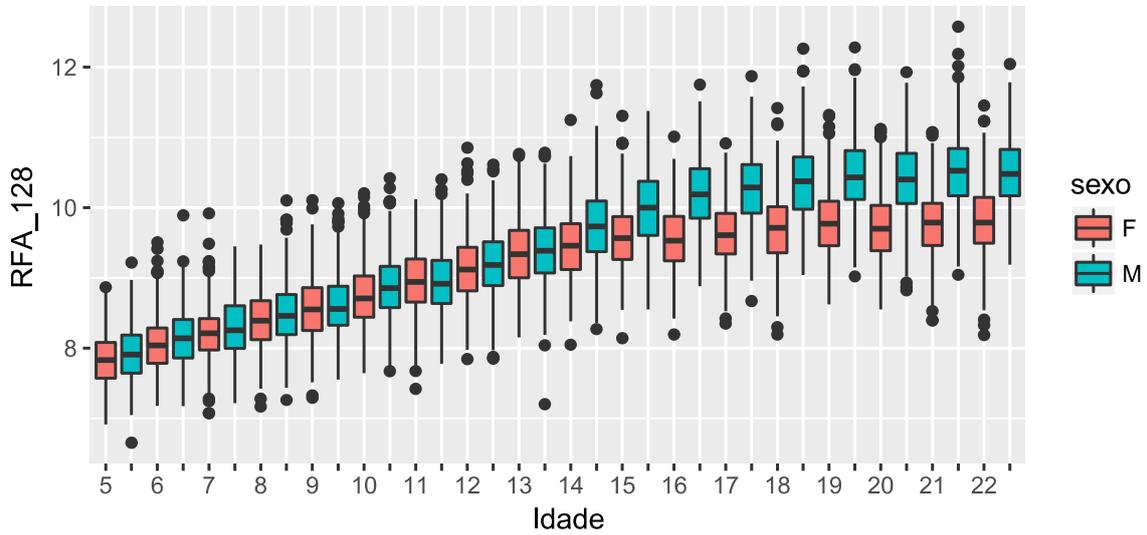
Distribuições da RFA_129 por Sexo e Idade

idades de 5 até 22 anos



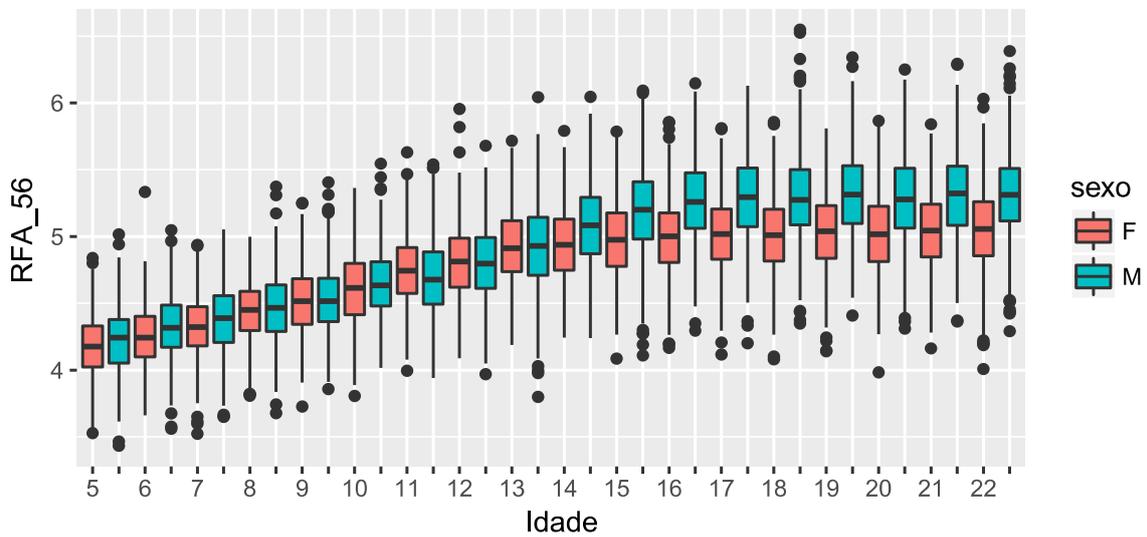
Distribuições da RFA_128 por Sexo e Idade

idades de 5 até 22 anos



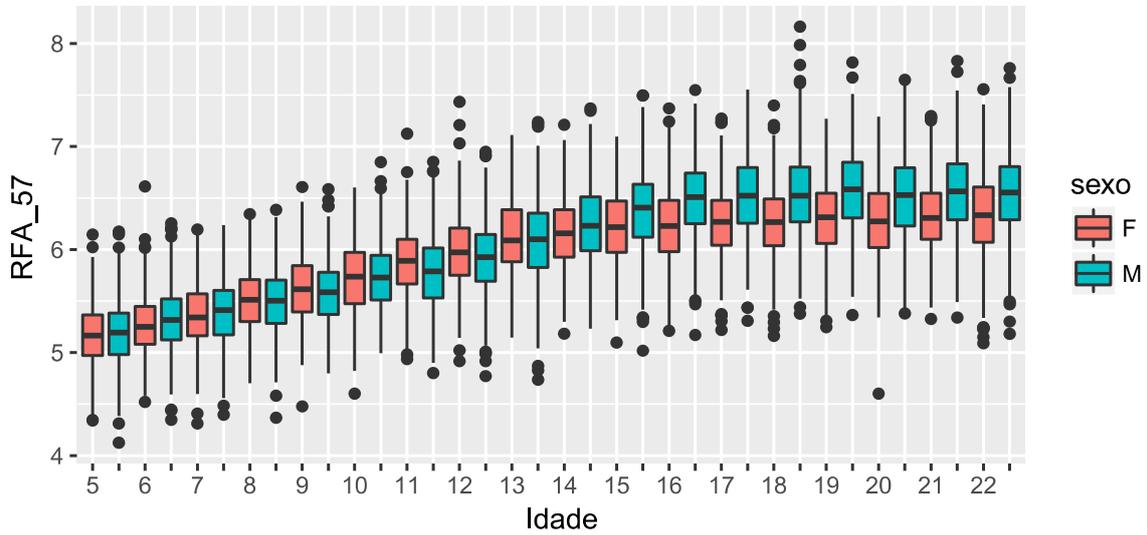
Distribuições da RFA_56 por Sexo e Idade

idades de 5 até 22 anos



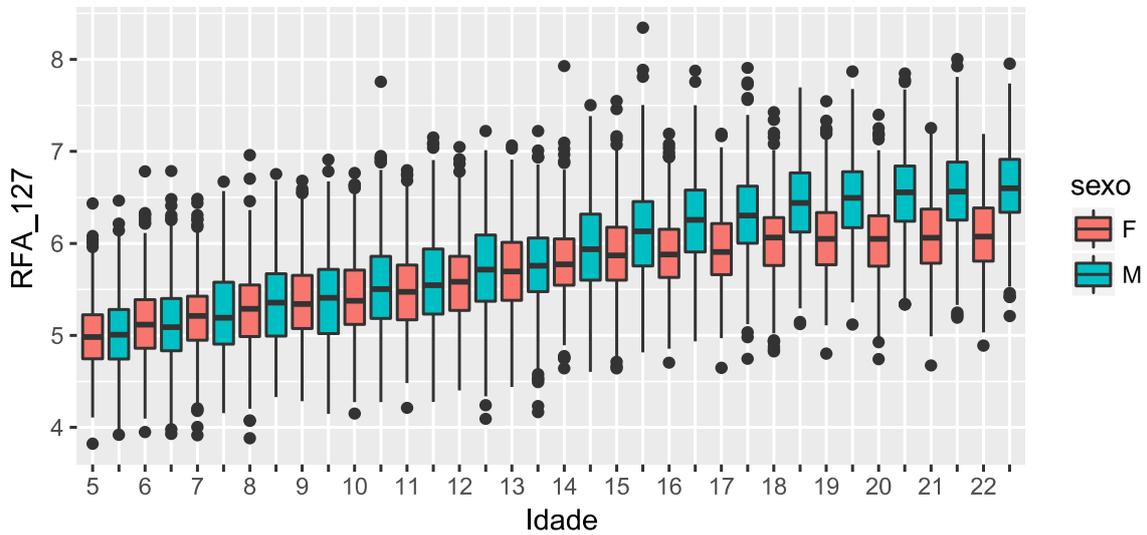
Distribuições da RFA_57 por Sexo e Idade

idades de 5 até 22 anos



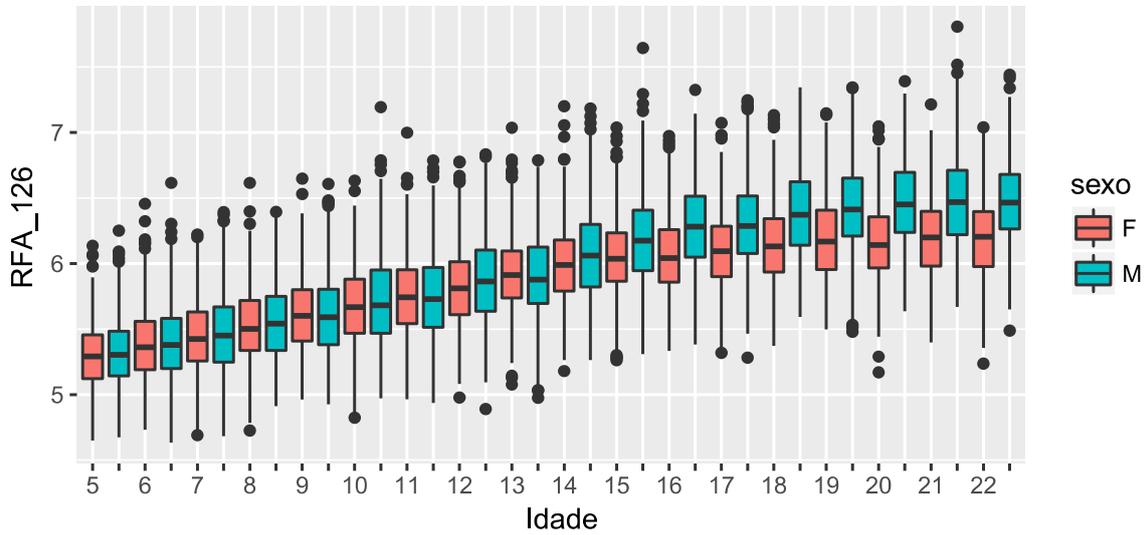
Distribuições da RFA_127 por Sexo e Idade

idades de 5 até 22 anos



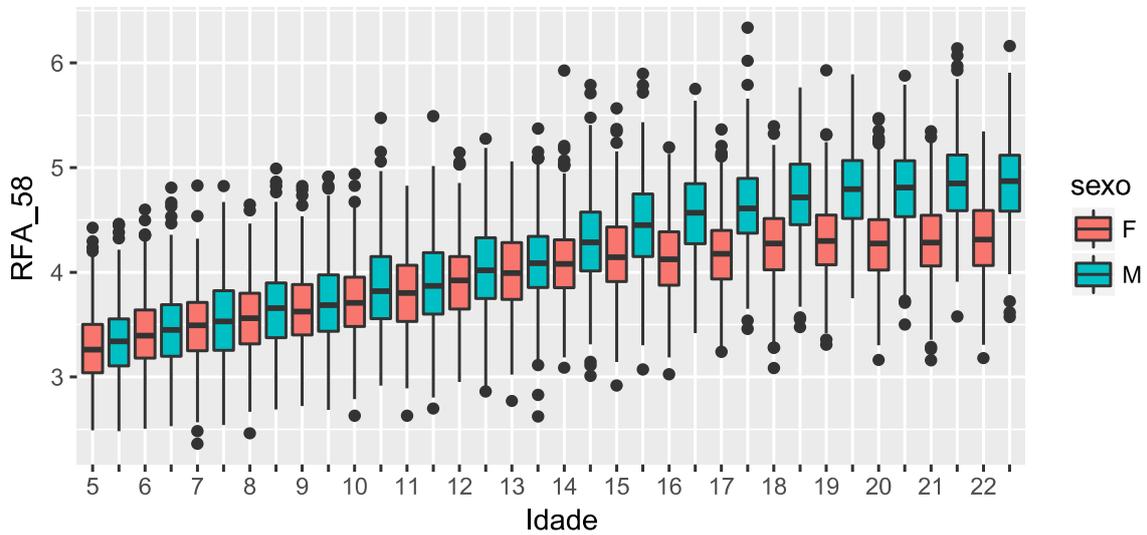
Distribuições da RFA_126 por Sexo e Idade

idades de 5 até 22 anos



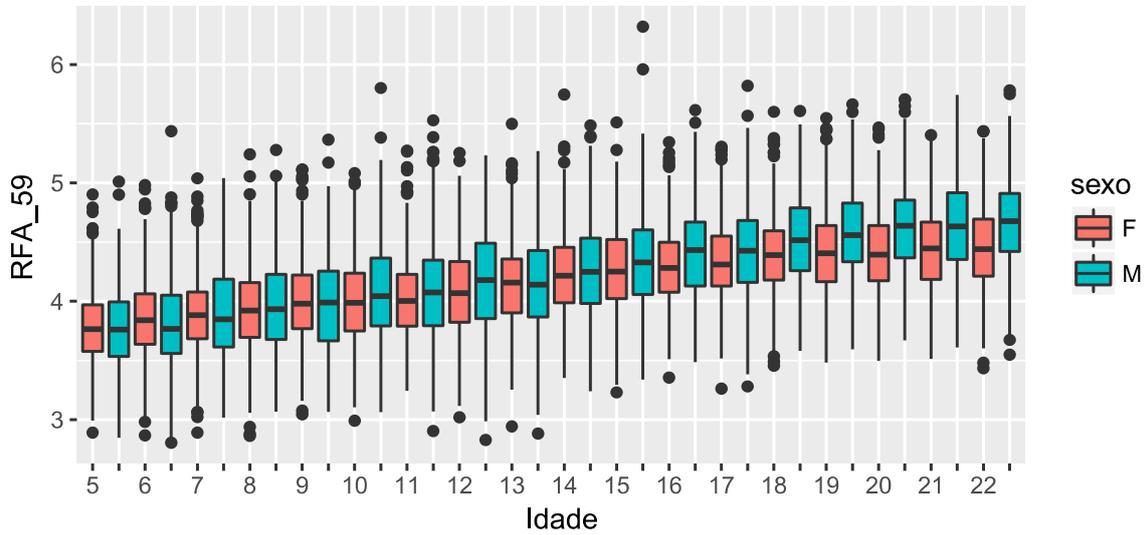
Distribuições da RFA_58 por Sexo e Idade

idades de 5 até 22 anos



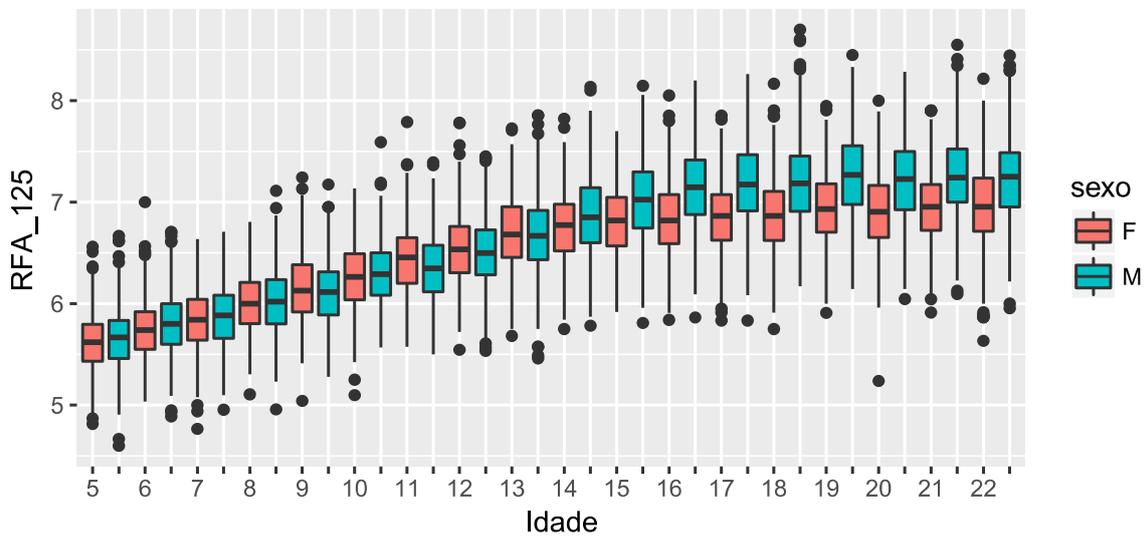
Distribuições da RFA_59 por Sexo e Idade

idades de 5 até 22 anos



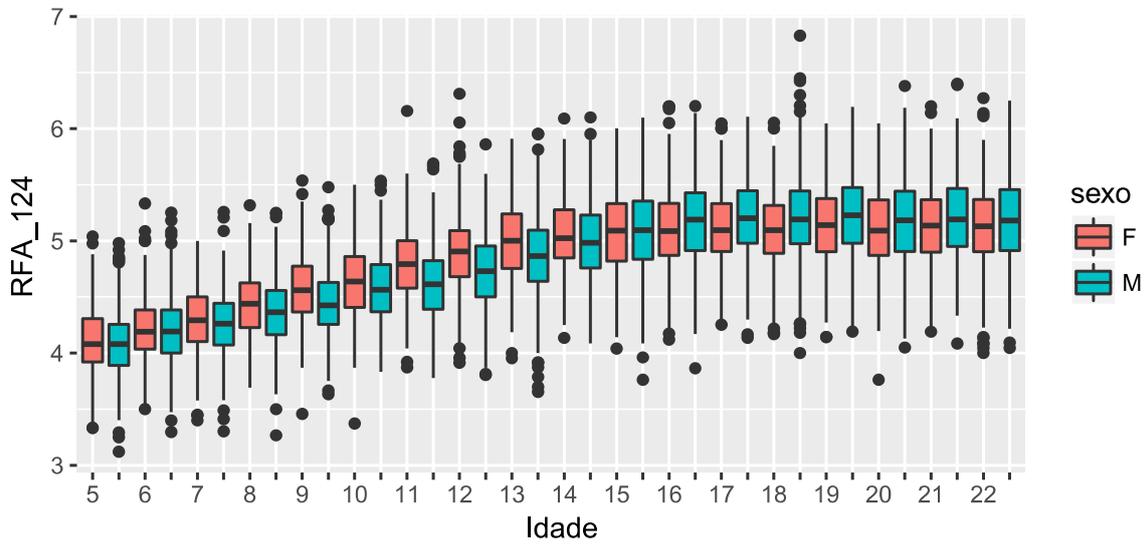
Distribuições da RFA_125 por Sexo e Idade

idades de 5 até 22 anos



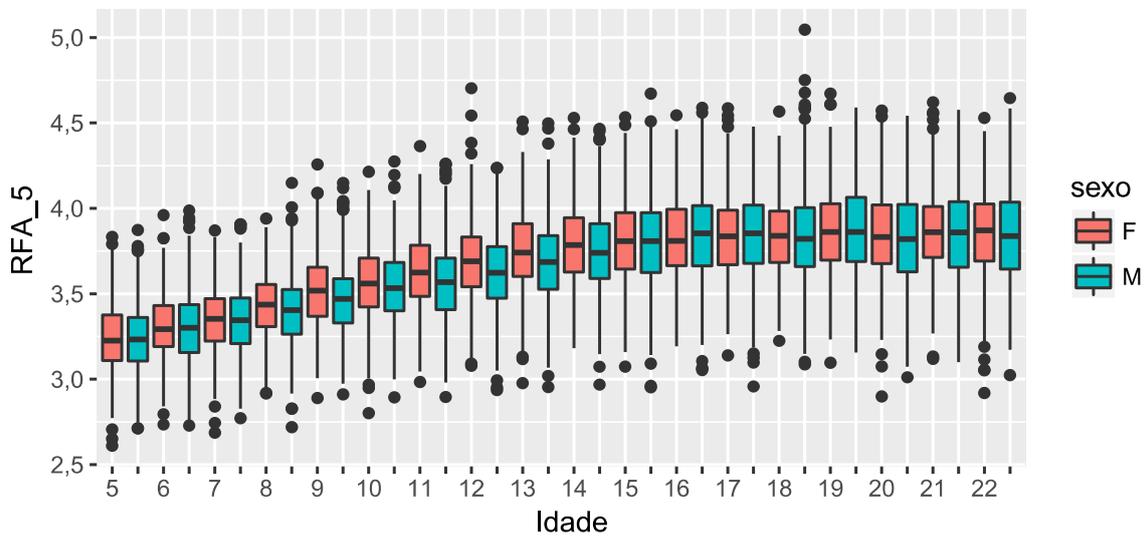
Distribuições da RFA_124 por Sexo e Idade

idades de 5 até 22 anos



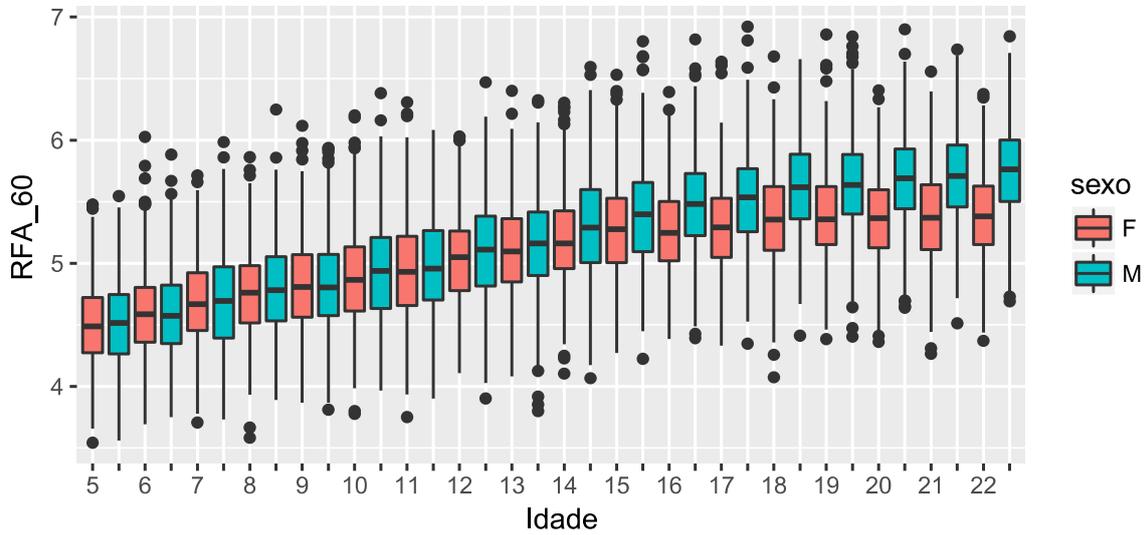
Distribuições da RFA_5 por Sexo e Idade

idades de 5 até 22 anos



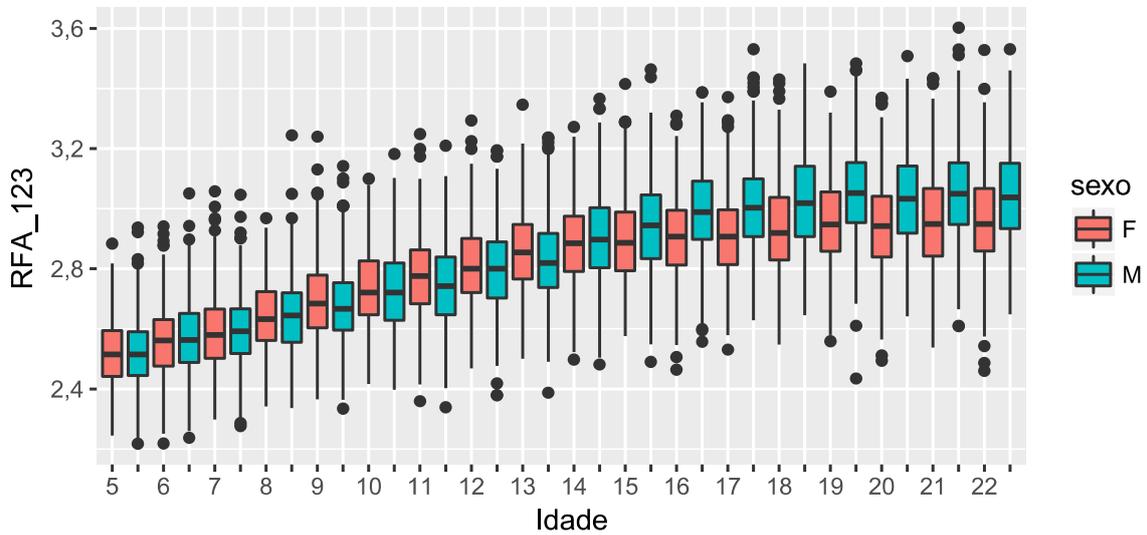
Distribuições da RFA_60 por Sexo e Idade

idades de 5 até 22 anos



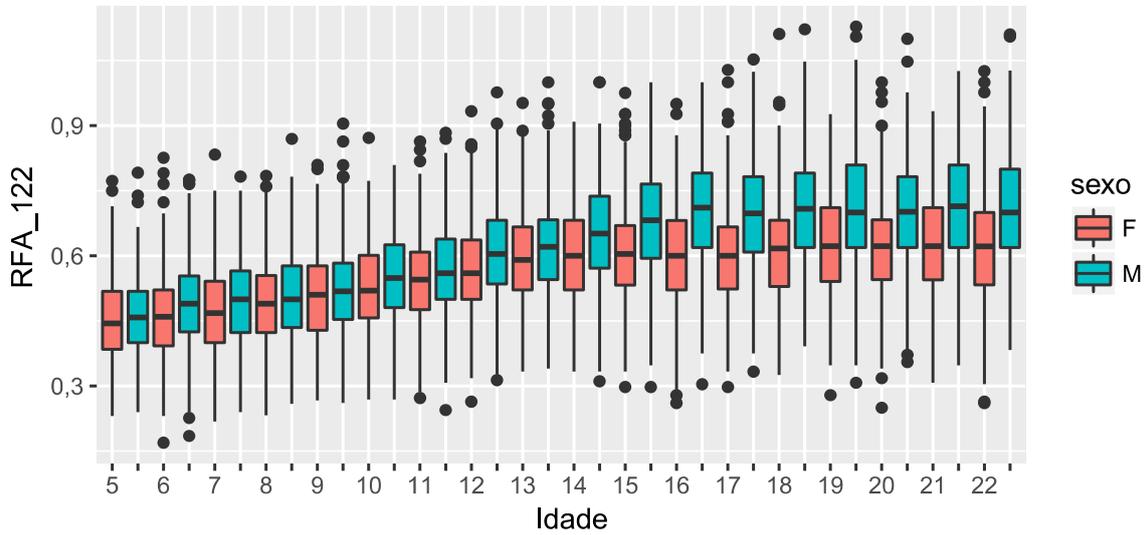
Distribuições da RFA_123 por Sexo e Idade

idades de 5 até 22 anos



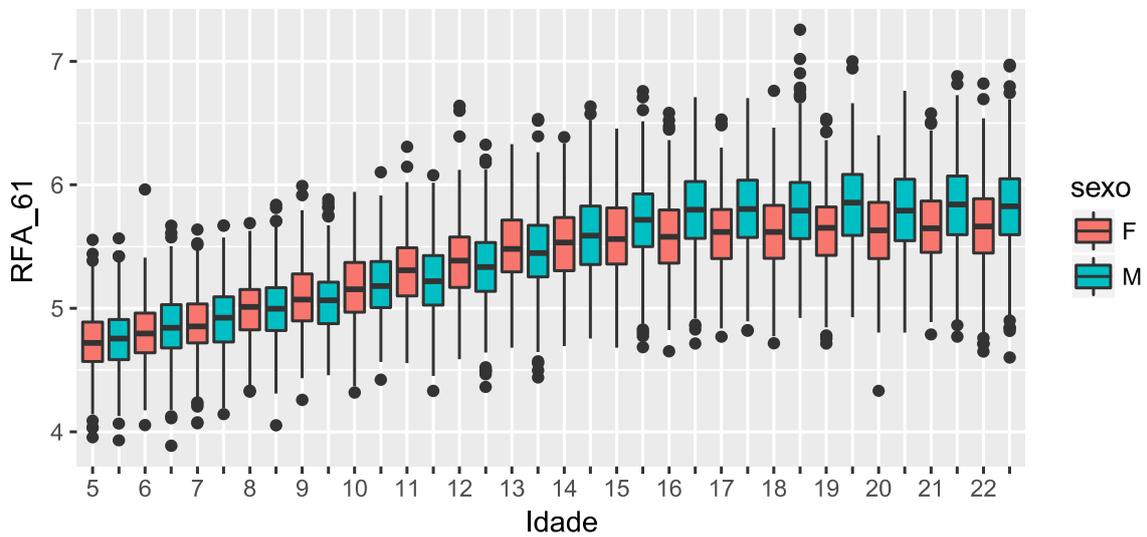
Distribuições da RFA_122 por Sexo e Idade

idades de 5 até 22 anos



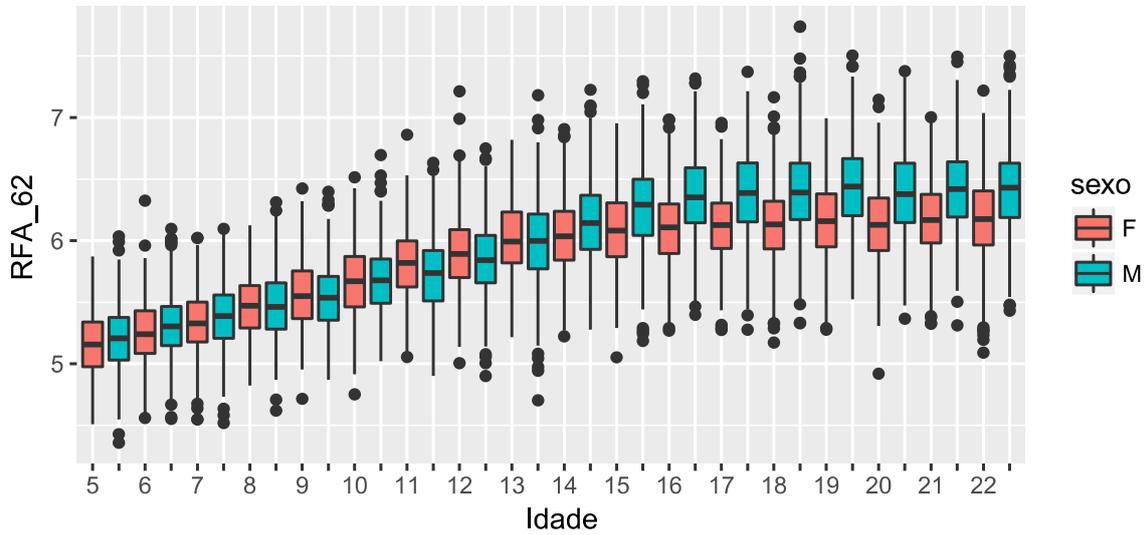
Distribuições da RFA_61 por Sexo e Idade

idades de 5 até 22 anos



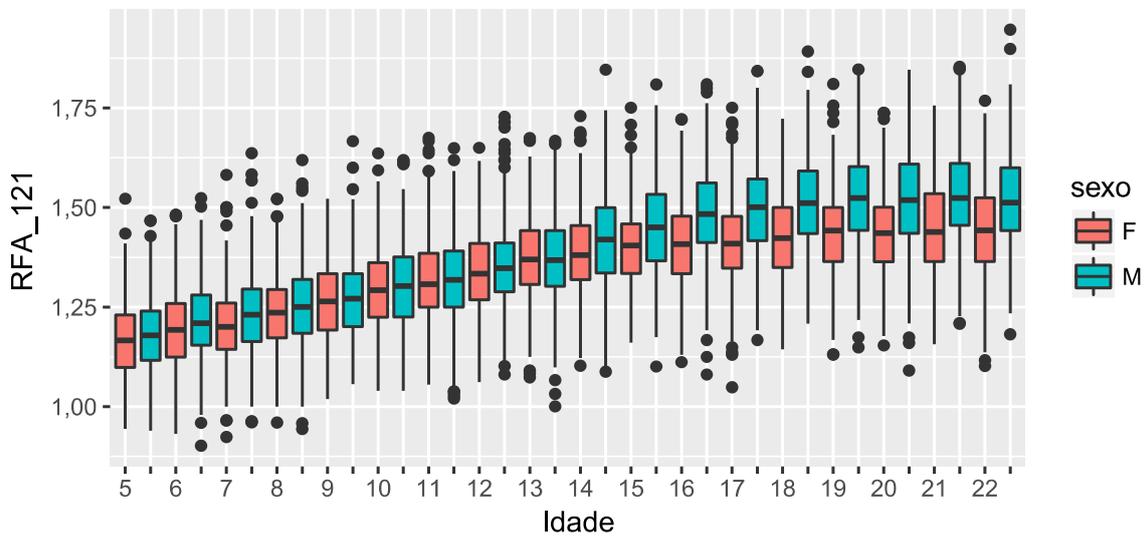
Distribuições da RFA_62 por Sexo e Idade

idades de 5 até 22 anos



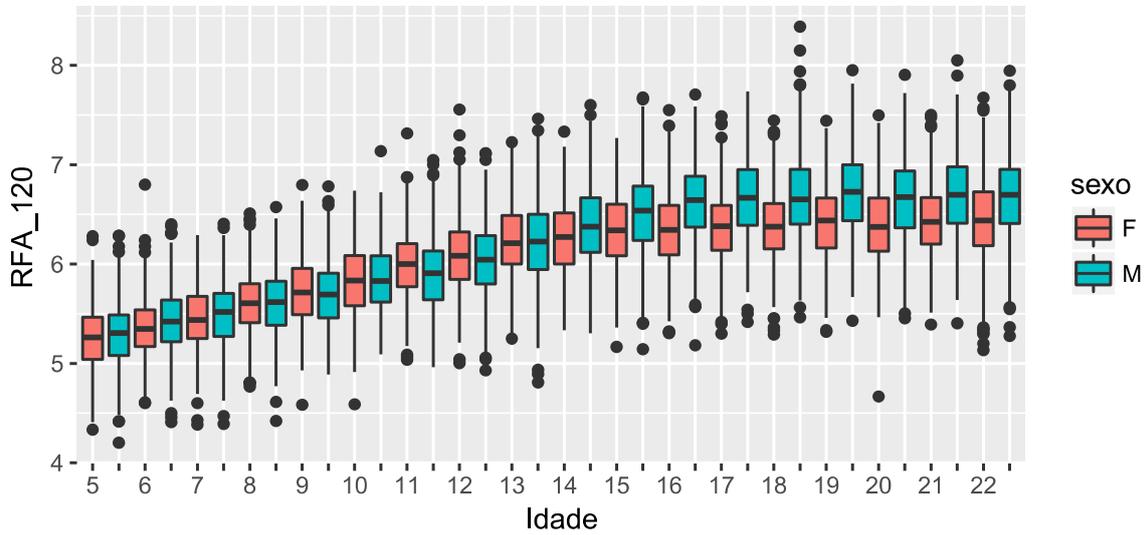
Distribuições da RFA_121 por Sexo e Idade

idades de 5 até 22 anos



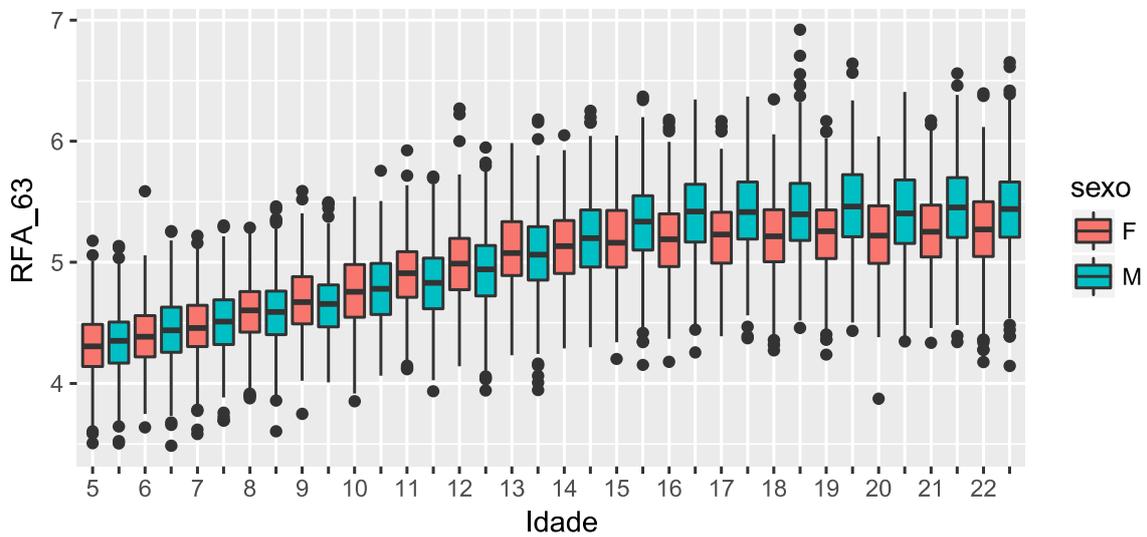
Distribuições da RFA_120 por Sexo e Idade

idades de 5 até 22 anos



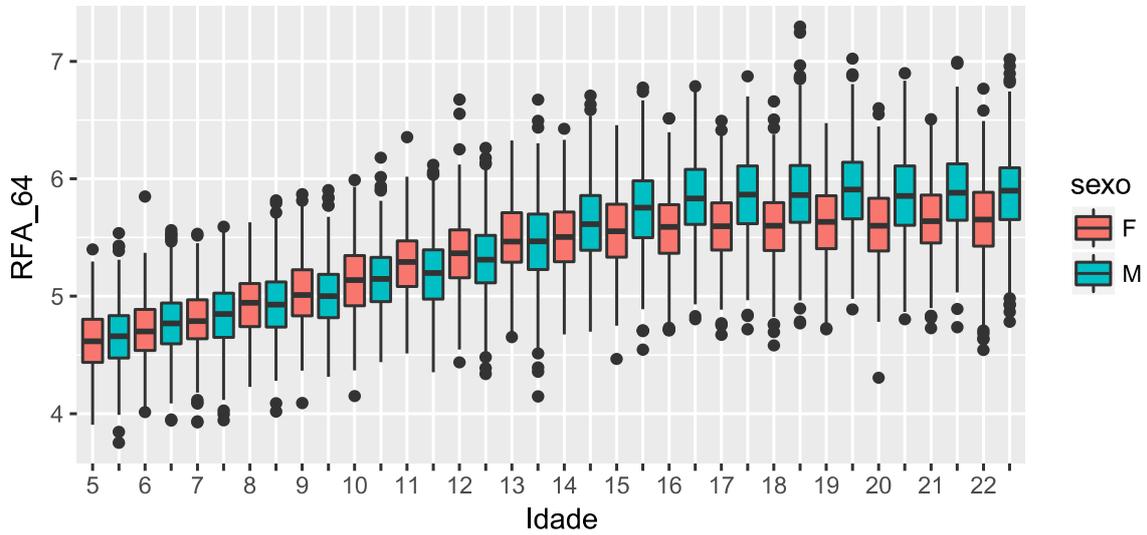
Distribuições da RFA_63 por Sexo e Idade

idades de 5 até 22 anos



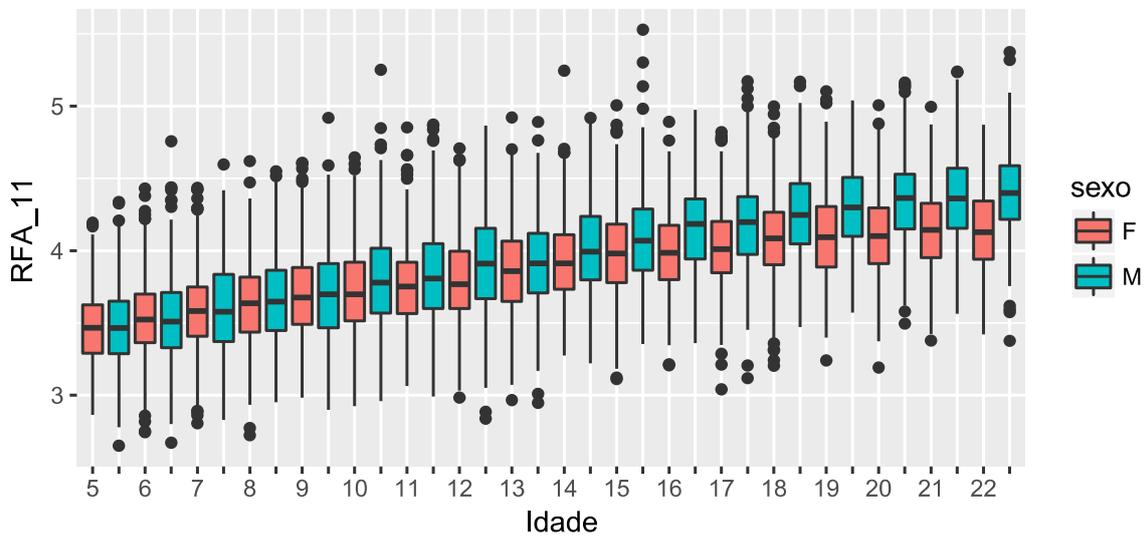
Distribuições da RFA_64 por Sexo e Idade

idades de 5 até 22 anos



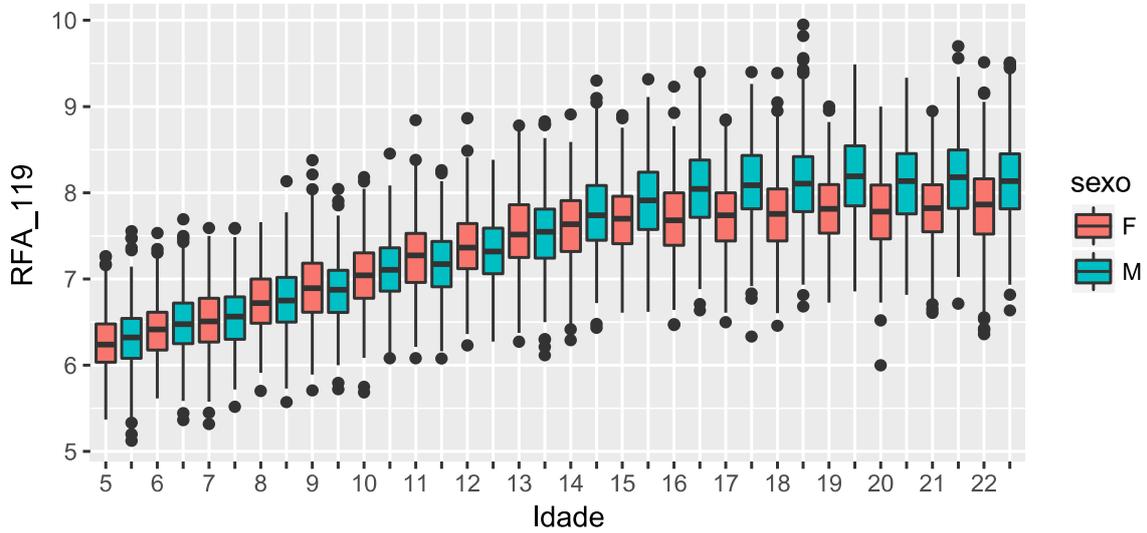
Distribuições da RFA_11 por Sexo e Idade

idades de 5 até 22 anos



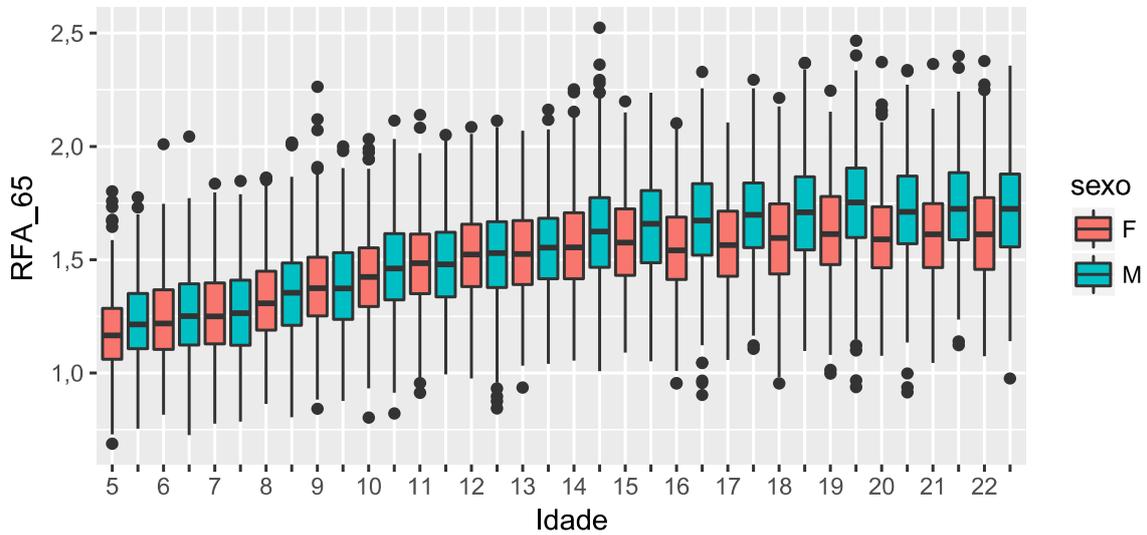
Distribuições da RFA_119 por Sexo e Idade

idades de 5 até 22 anos



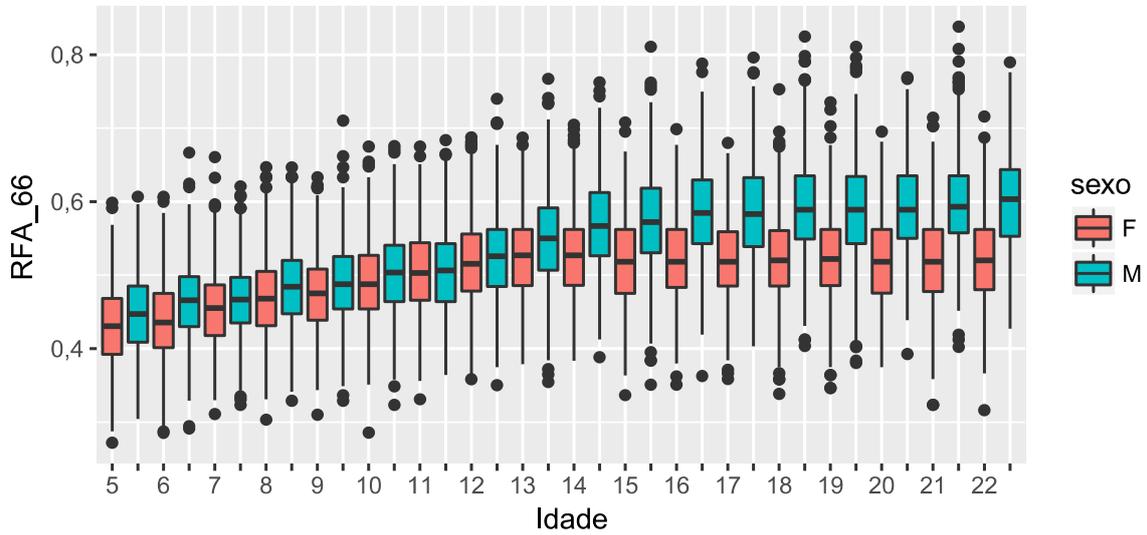
Distribuições da RFA_65 por Sexo e Idade

idades de 5 até 22 anos



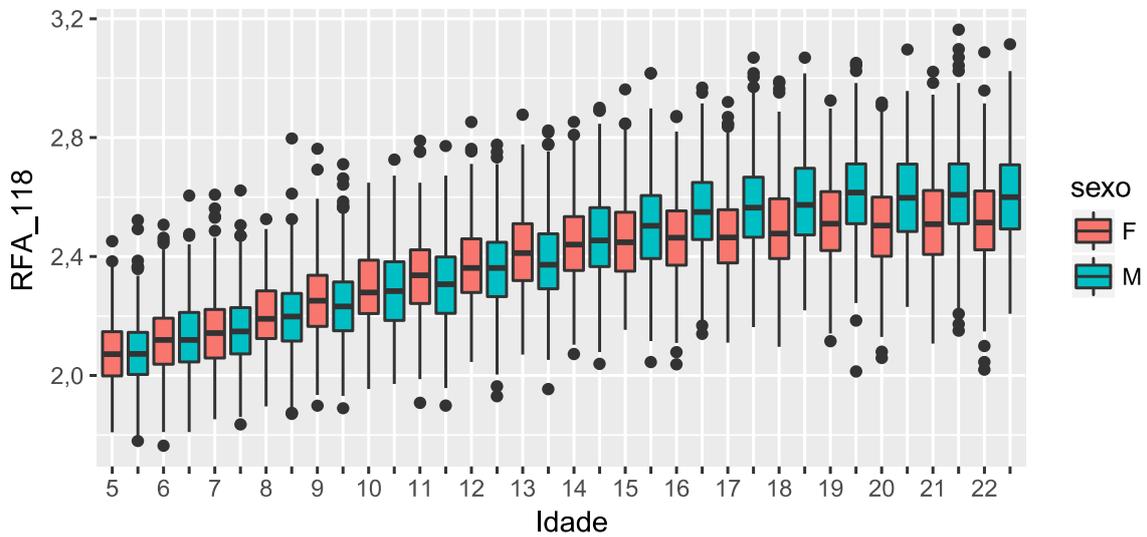
Distribuições da RFA_66 por Sexo e Idade

idades de 5 até 22 anos



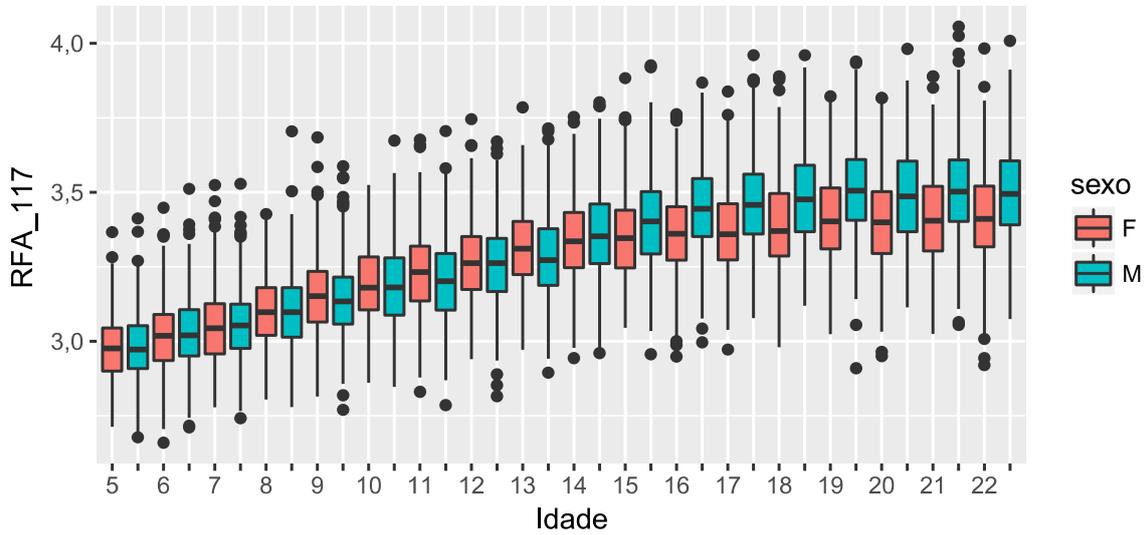
Distribuições da RFA_118 por Sexo e Idade

idades de 5 até 22 anos



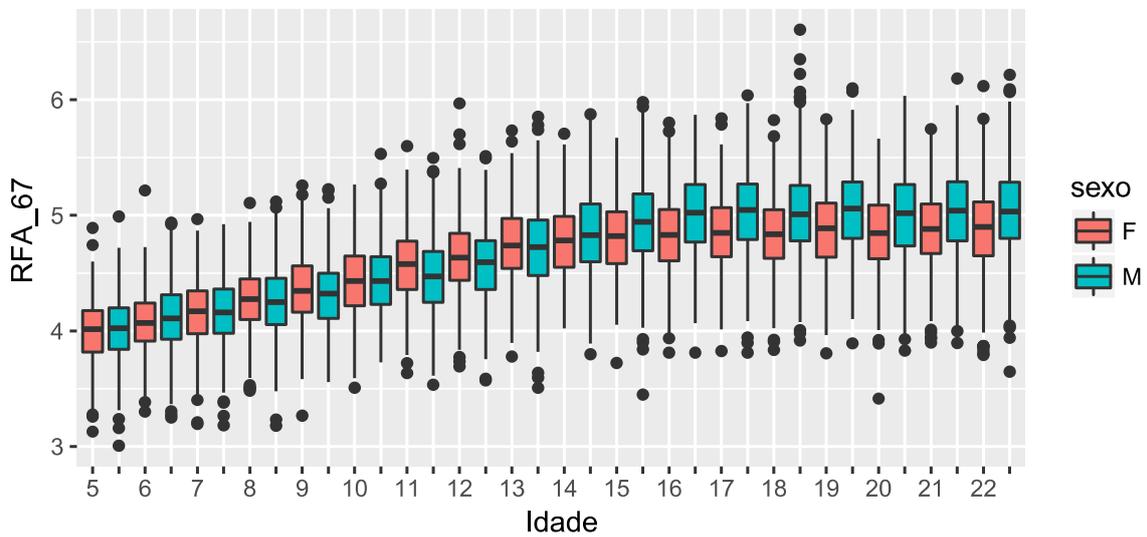
Distribuições da RFA_117 por Sexo e Idade

idades de 5 até 22 anos



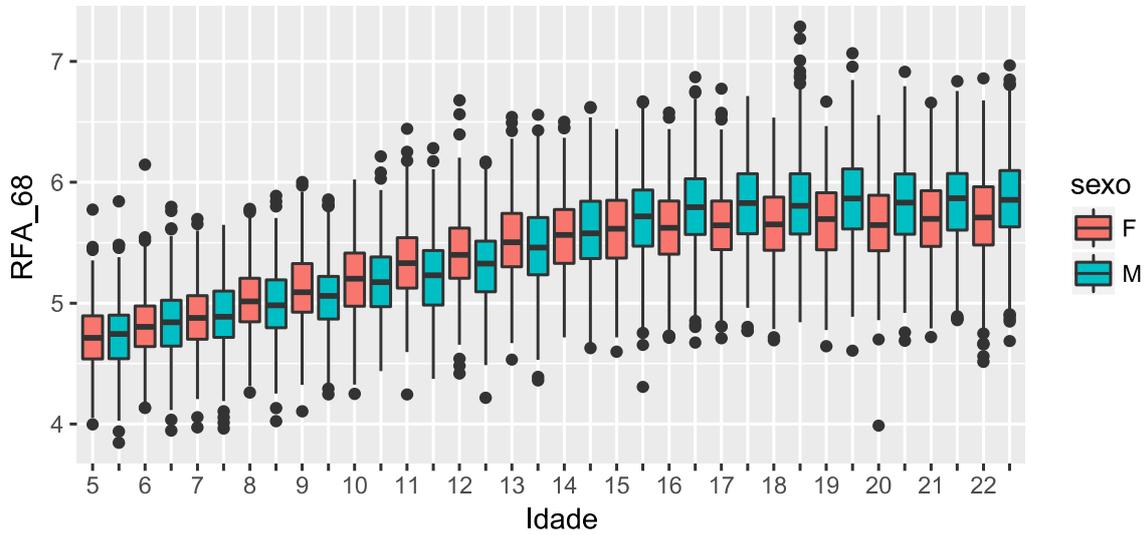
Distribuições da RFA_67 por Sexo e Idade

idades de 5 até 22 anos



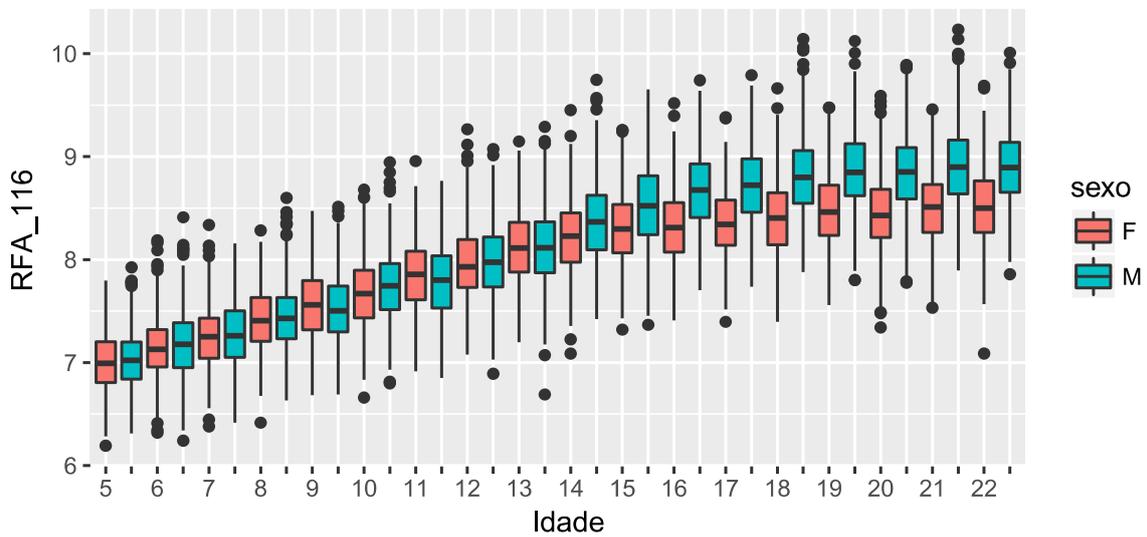
Distribuições da RFA_68 por Sexo e Idade

idades de 5 até 22 anos



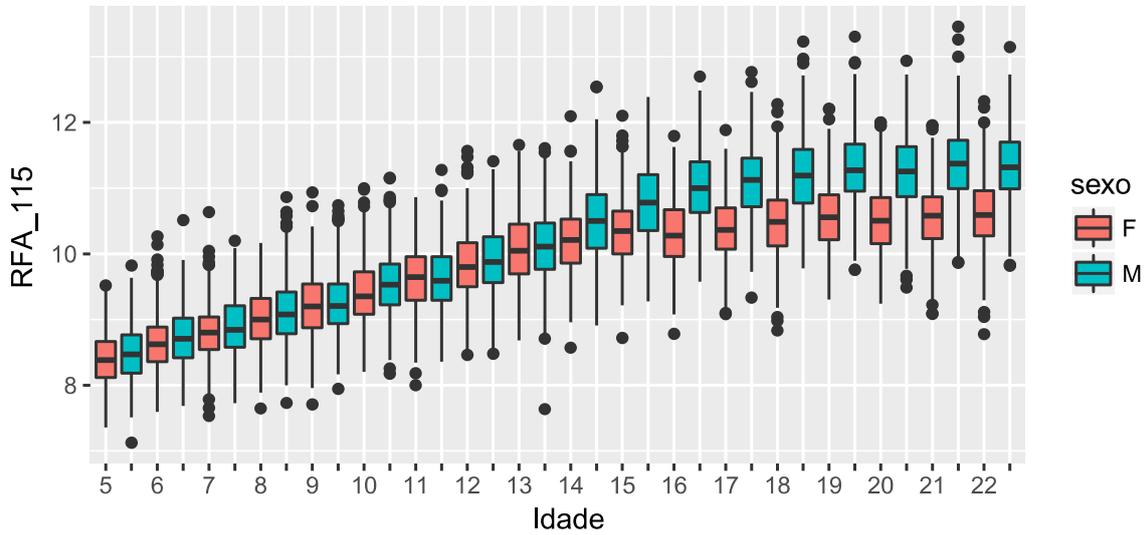
Distribuições da RFA_116 por Sexo e Idade

idades de 5 até 22 anos



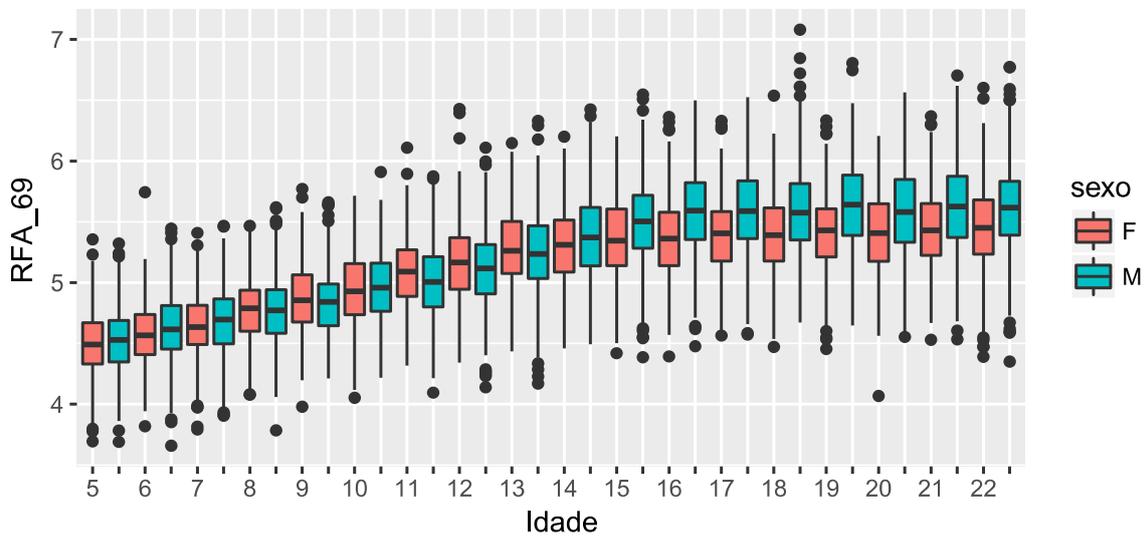
Distribuições da RFA_115 por Sexo e Idade

idades de 5 até 22 anos



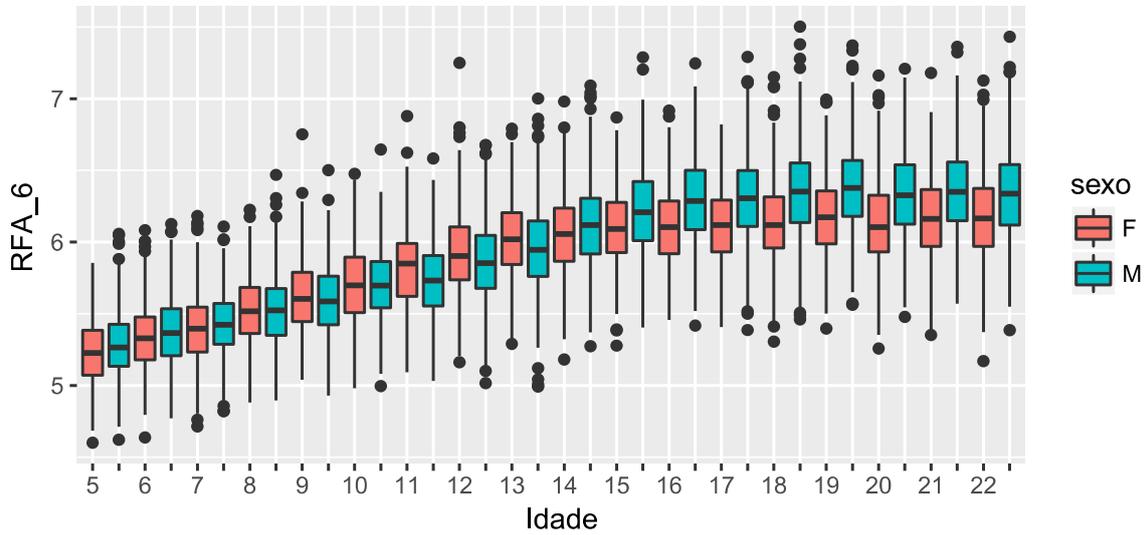
Distribuições da RFA_69 por Sexo e Idade

idades de 5 até 22 anos



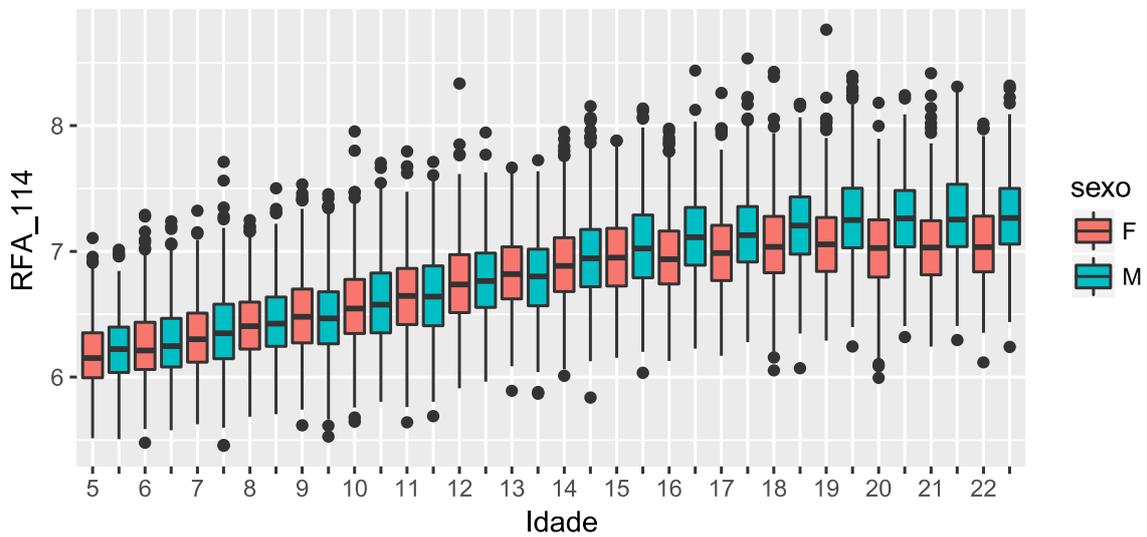
Distribuições dax and Idade

idades de 5 até 22 anos



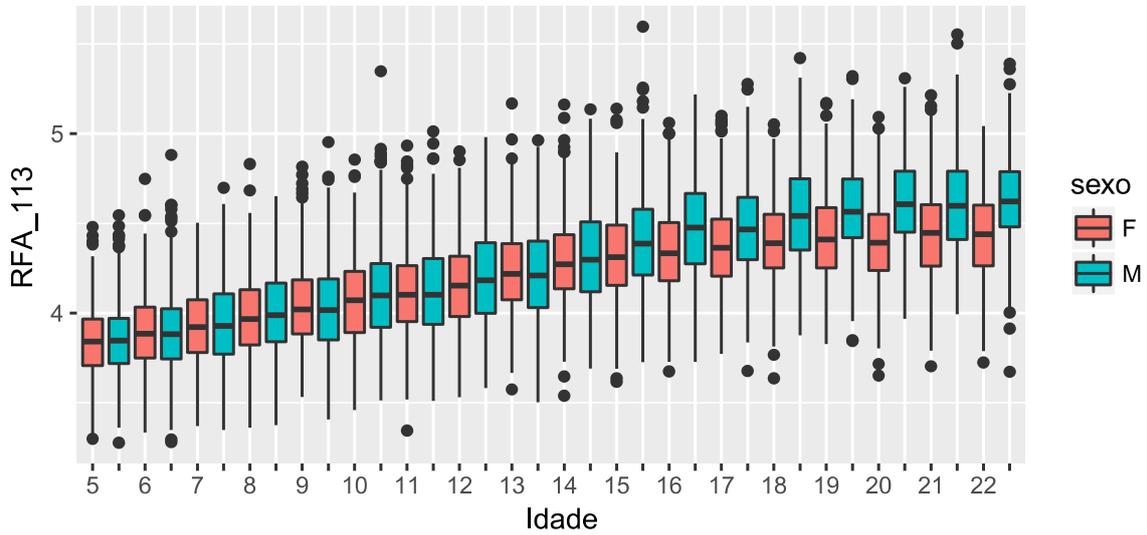
Distribuições da RFA_114 por Sexo e Idade

idades de 5 até 22 anos



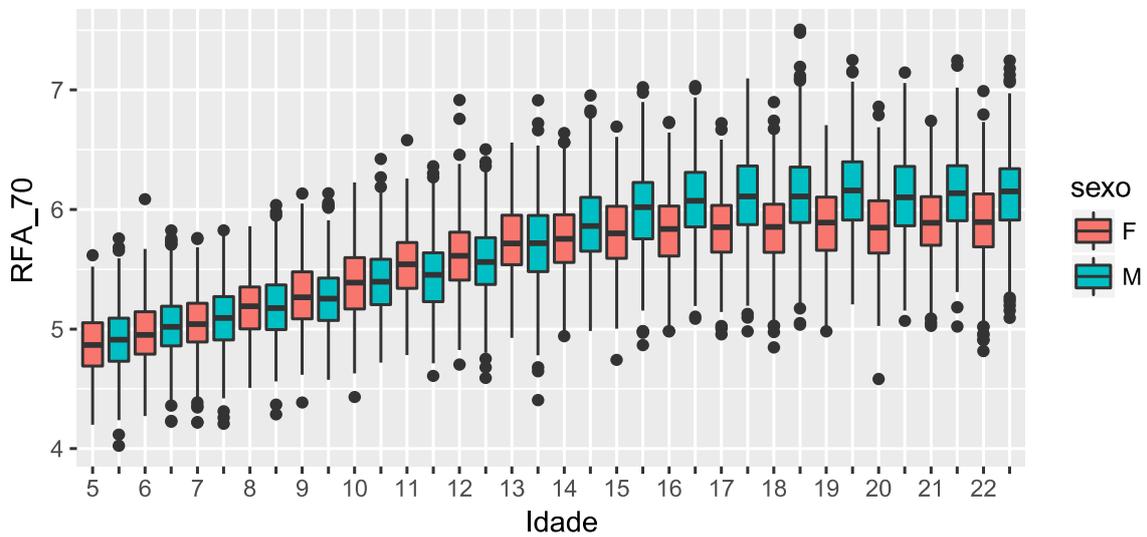
Distribuições da RFA_113 por Sexo e Idade

idades de 5 até 22 anos



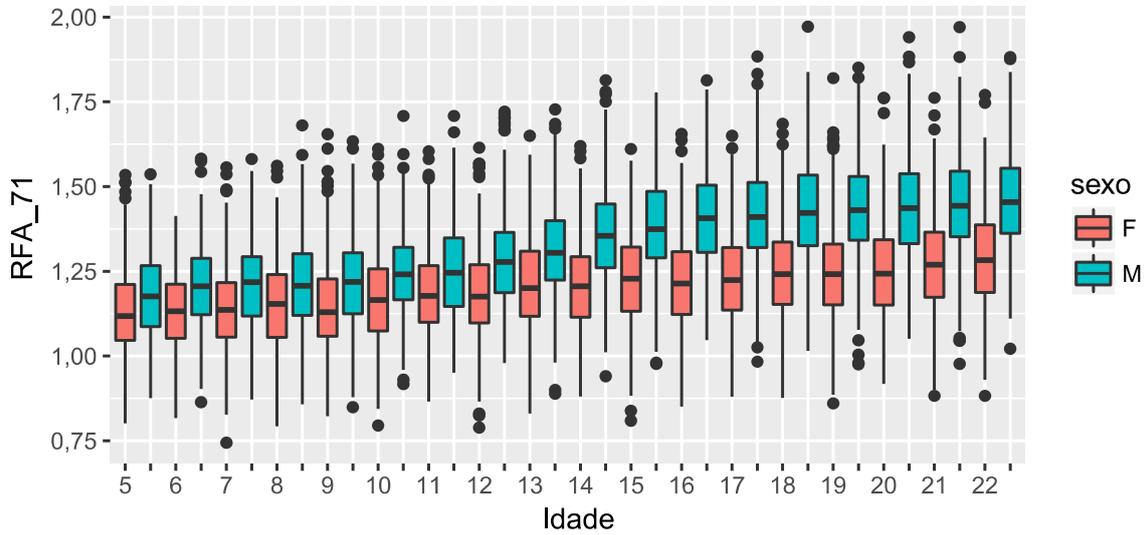
Distribuições da RFA_70 por Sexo e Idade

idades de 5 até 22 anos



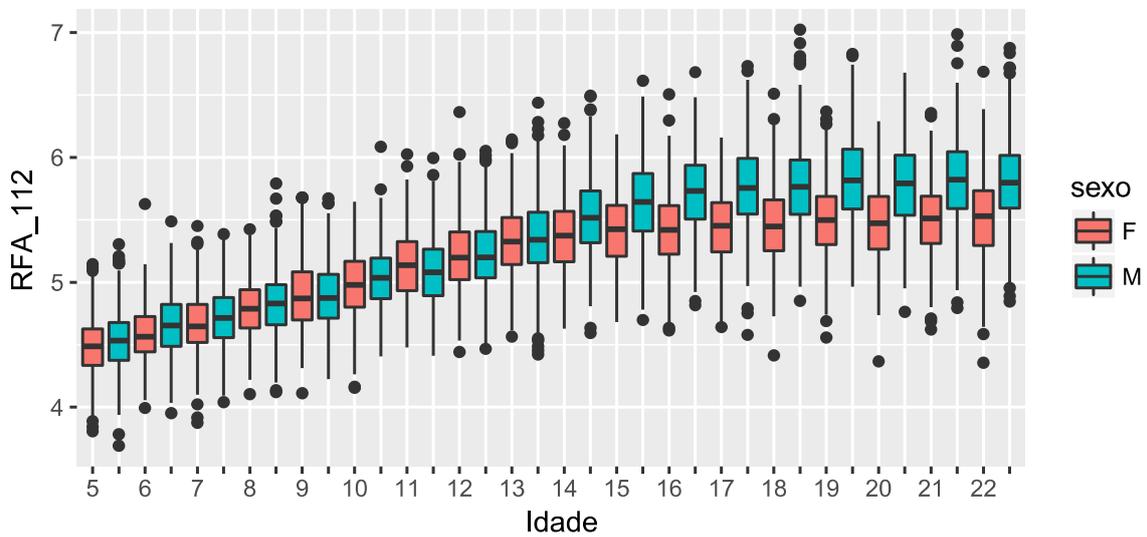
Distribuições da RFA_71 por Sexo e Idade

idades de 5 até 22 anos



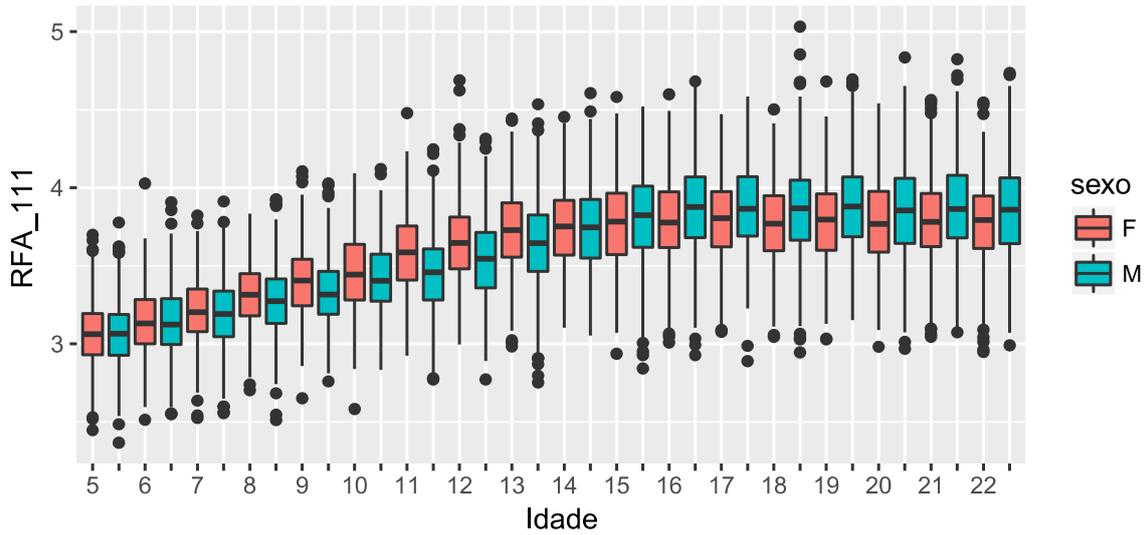
Distribuições da RFA_112 por Sexo e Idade

idades de 5 até 22 anos



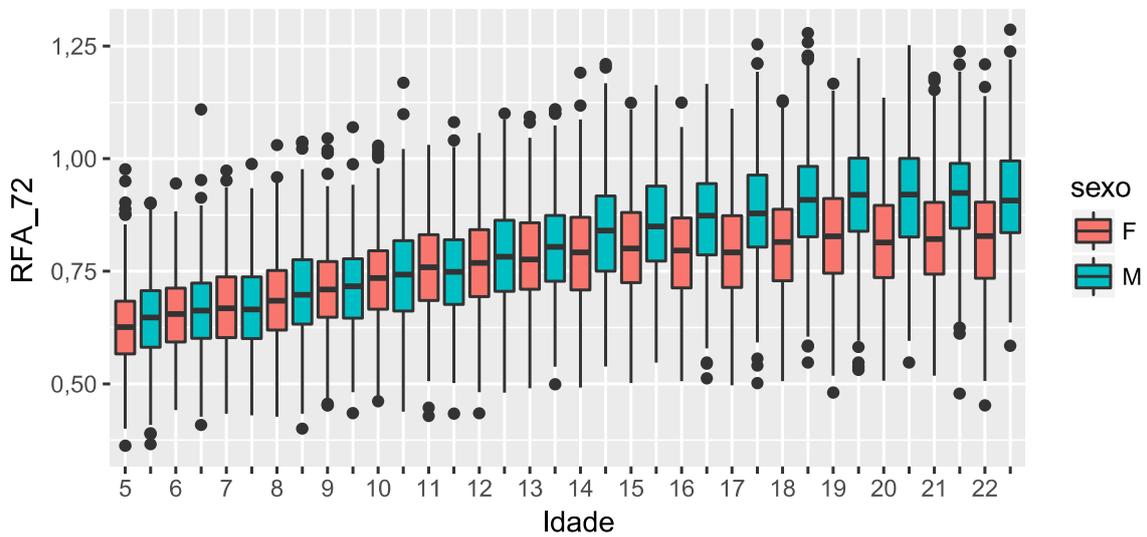
Distribuições da RFA_111 por Sexo e Idade

idades de 5 até 22 anos



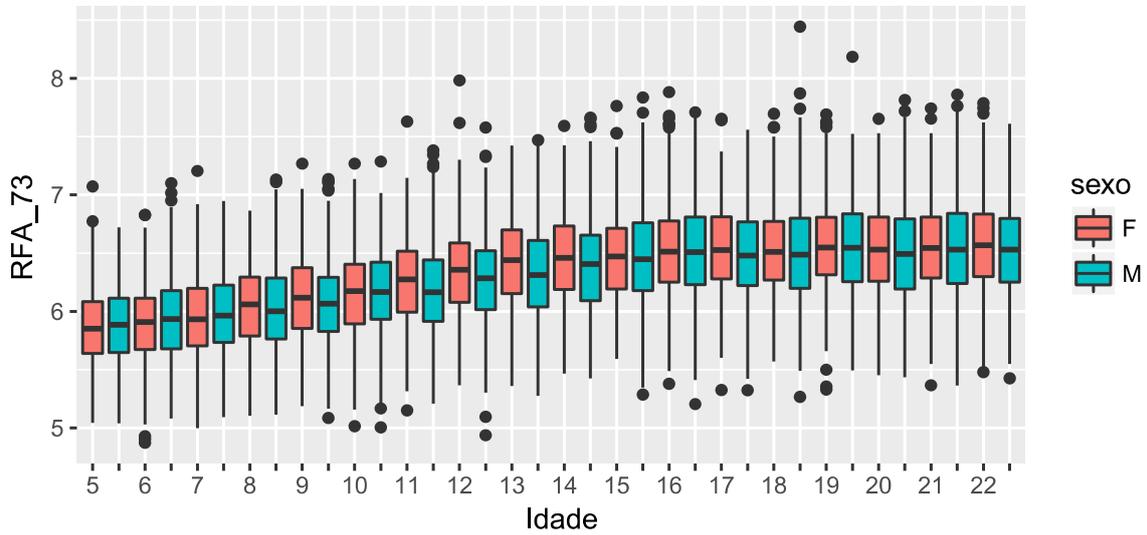
Distribuições da RFA_72 por Sexo e Idade

idades de 5 até 22 anos



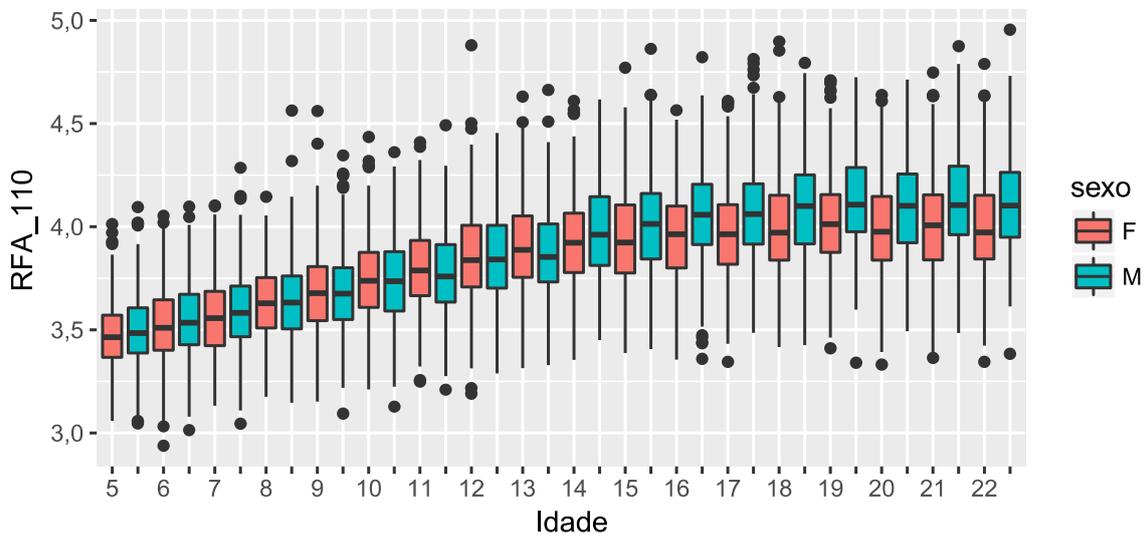
Distribuições da RFA_73 por Sexo e Idade

idades de 5 até 22 anos



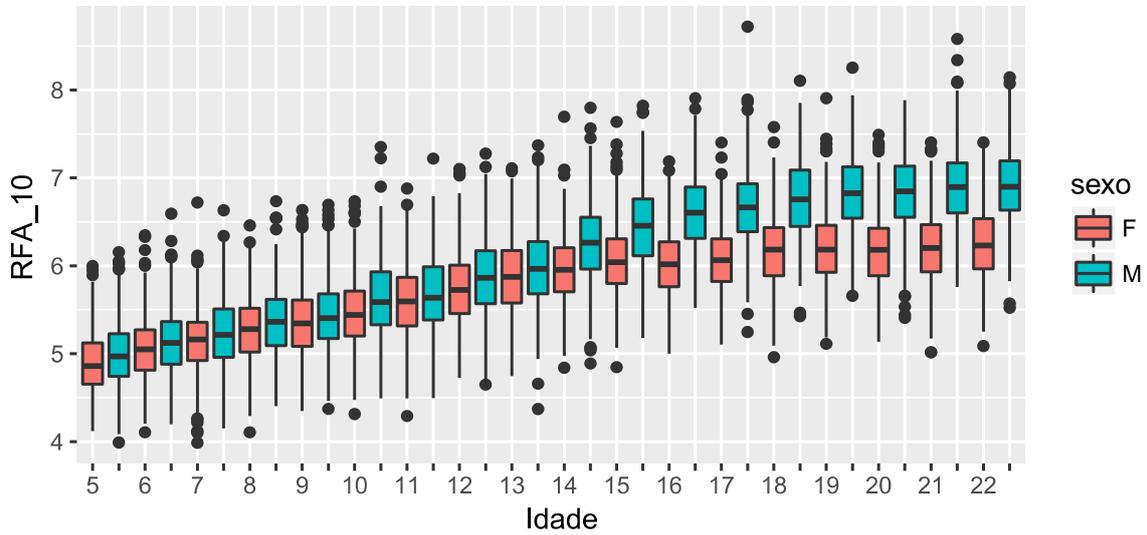
Distribuições da RFA_110 por Sexo e Idade

idades de 5 até 22 anos



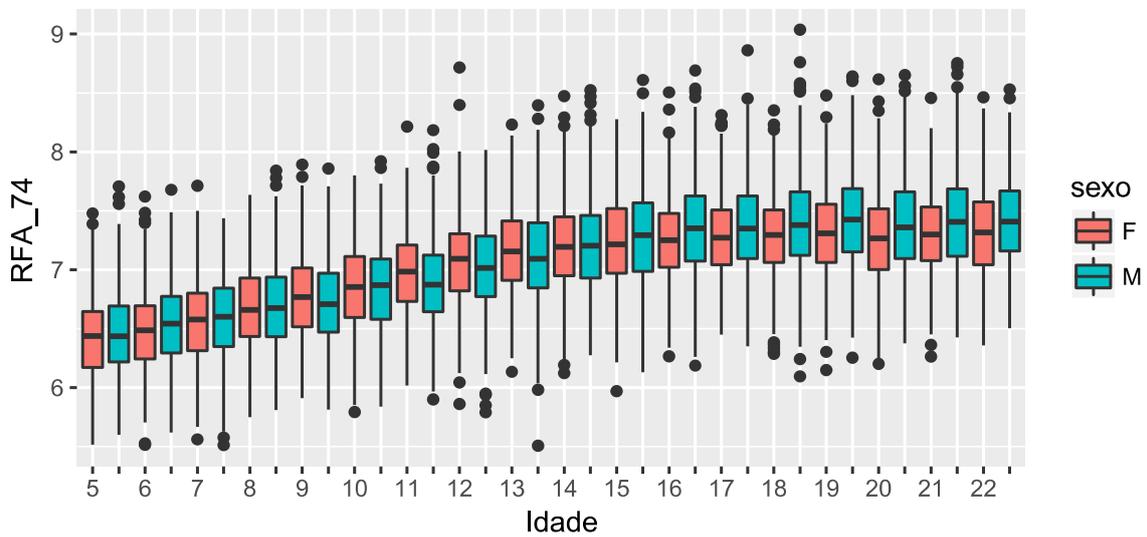
Distribuições da RFA_10 por Sexo e Idade

idades de 5 até 22 anos



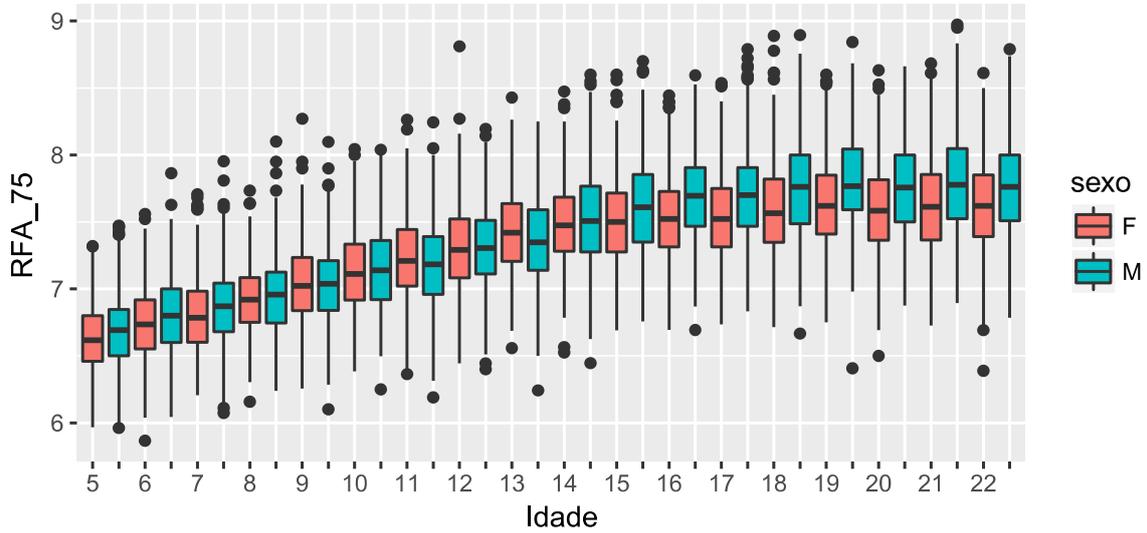
Distribuições da RFA_74 por Sexo e Idade

idades de 5 até 22 anos



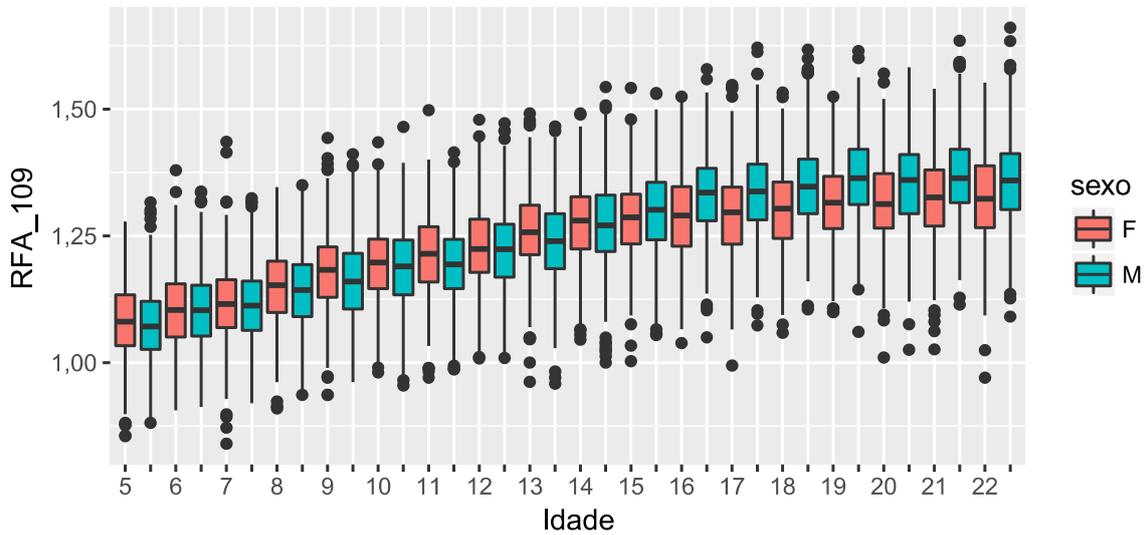
Distribuições da RFA_75 por Sexo e Idade

idades de 5 até 22 anos



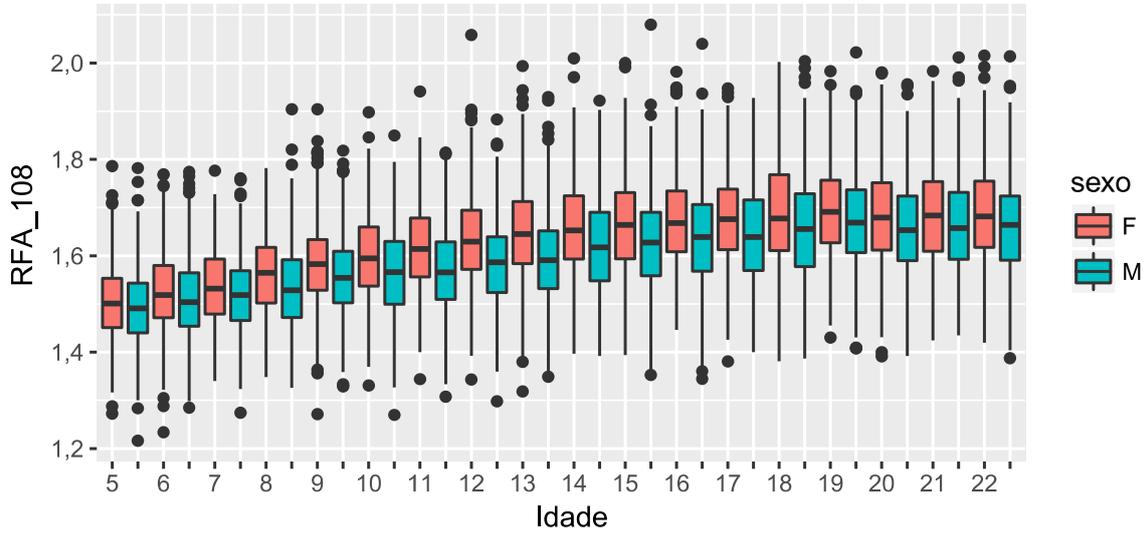
Distribuições da RFA_109 por Sexo e Idade

idades de 5 até 22 anos



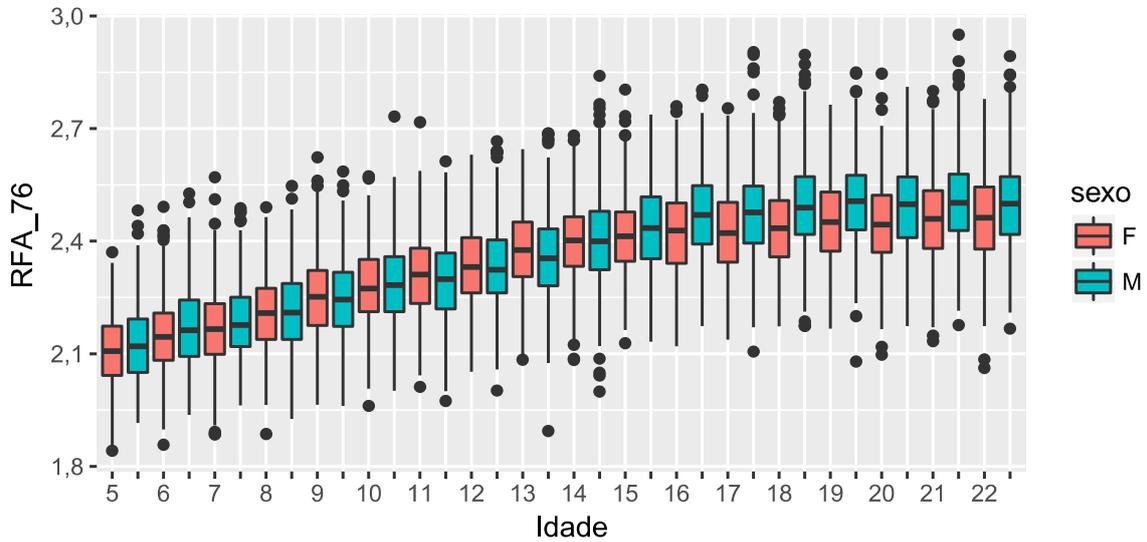
Distribuições da RFA_108 por Sexo e Idade

idades de 5 até 22 anos



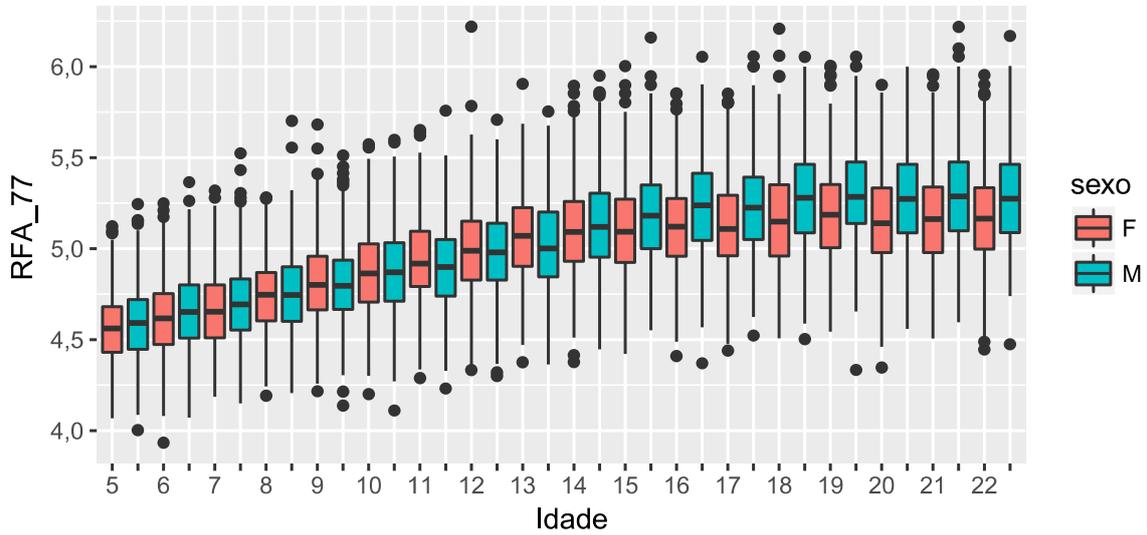
Distribuições da RFA_76 por Sexo e Idade

idades de 5 até 22 anos



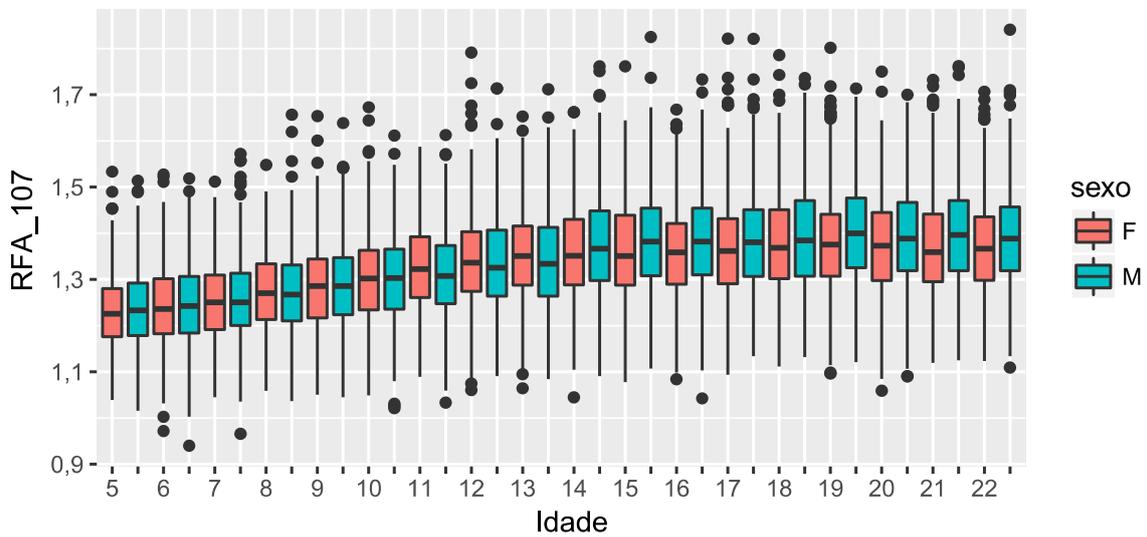
Distribuições da RFA_77 por Sexo e Idade

idades de 5 até 22 anos



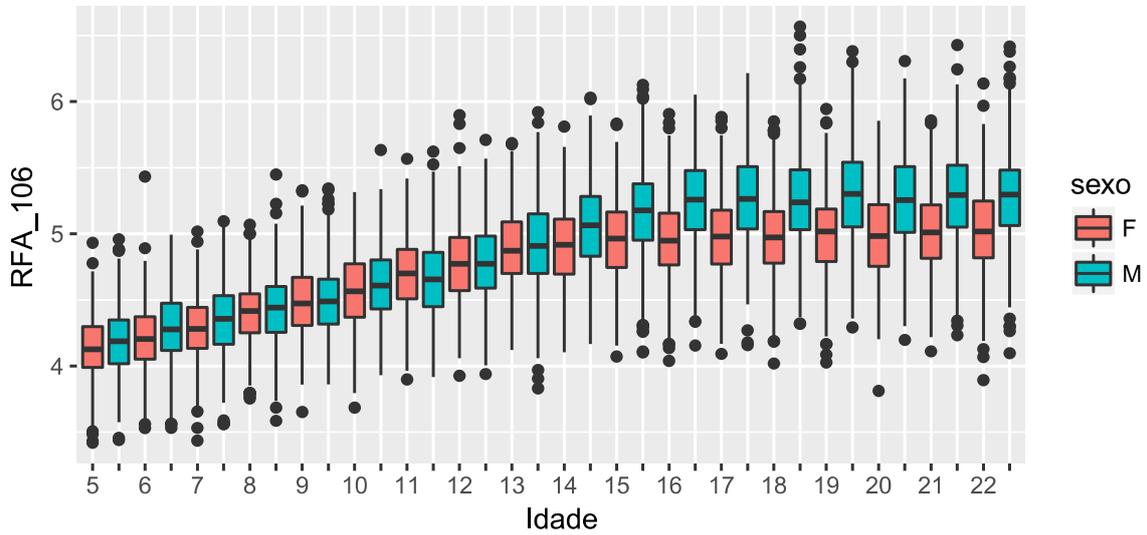
Distribuições da RFA_107 por Sexo e Idade

idades de 5 até 22 anos



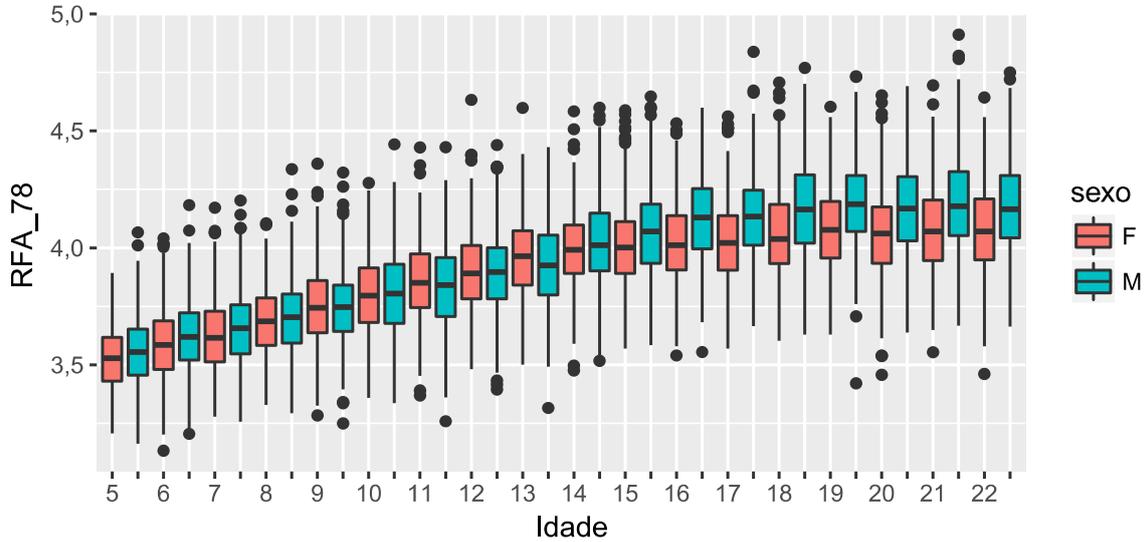
Distribuições da RFA_106 por Sexo e Idade

idades de 5 até 22 anos



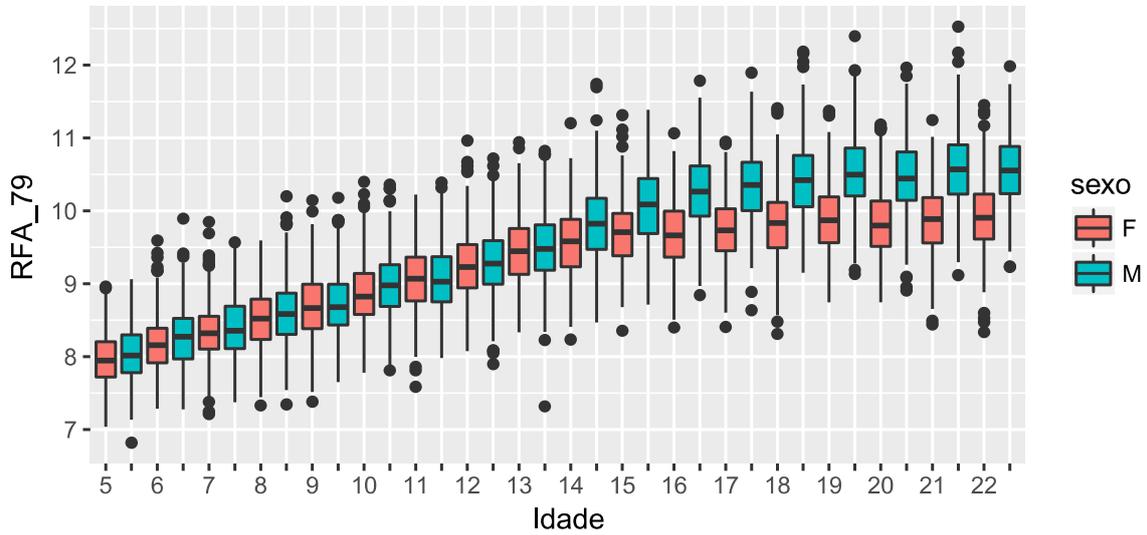
Distribuições da RFA_78 por Sexo e Idade

idades de 5 até 22 anos



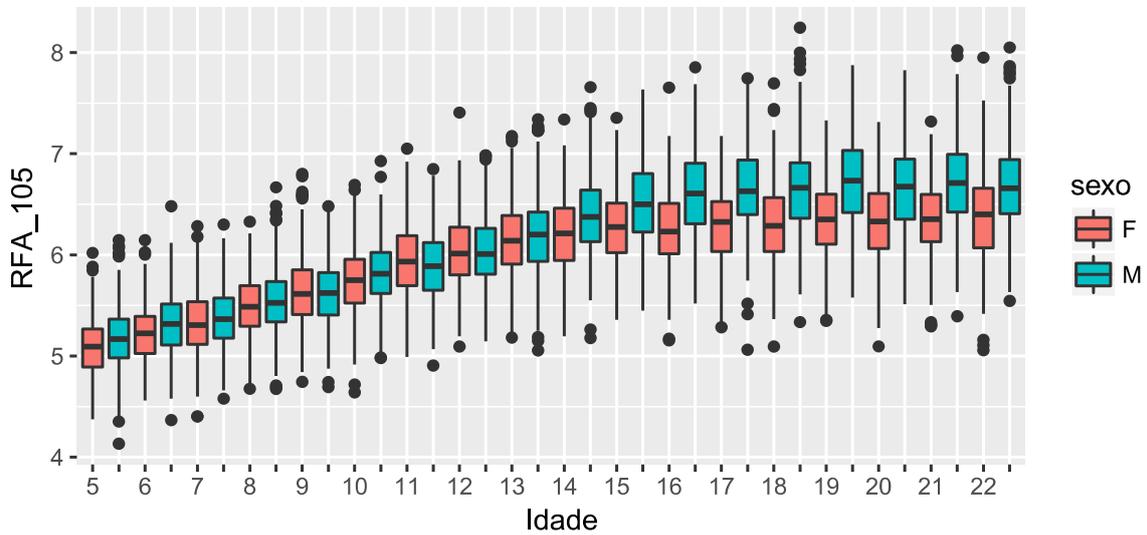
Distribuições daex and Idade

idades de 5 até 22 anos



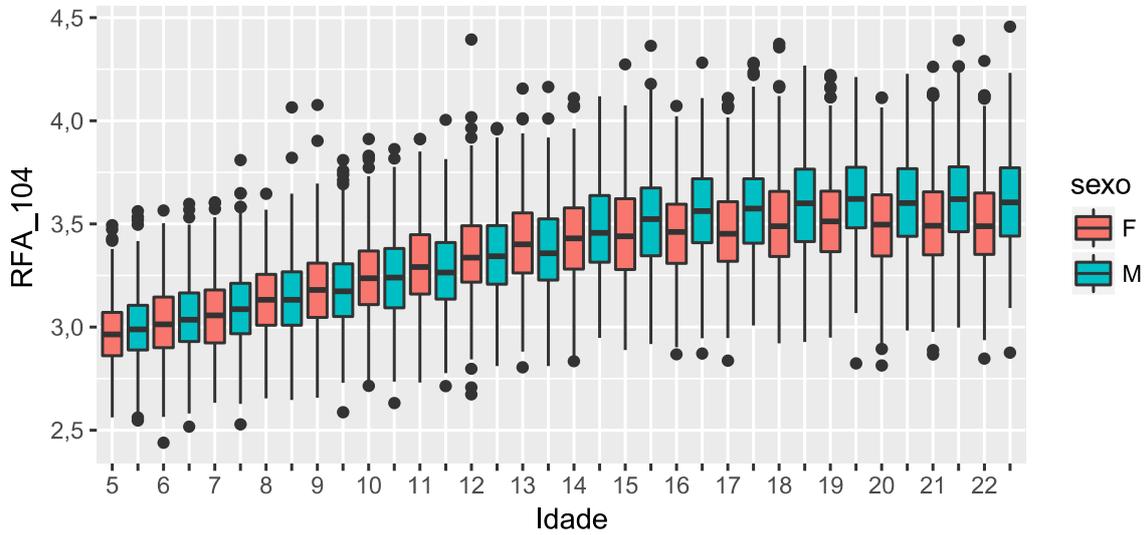
Distribuições da RFA_105 por Sexo e Idade

idades de 5 até 22 anos



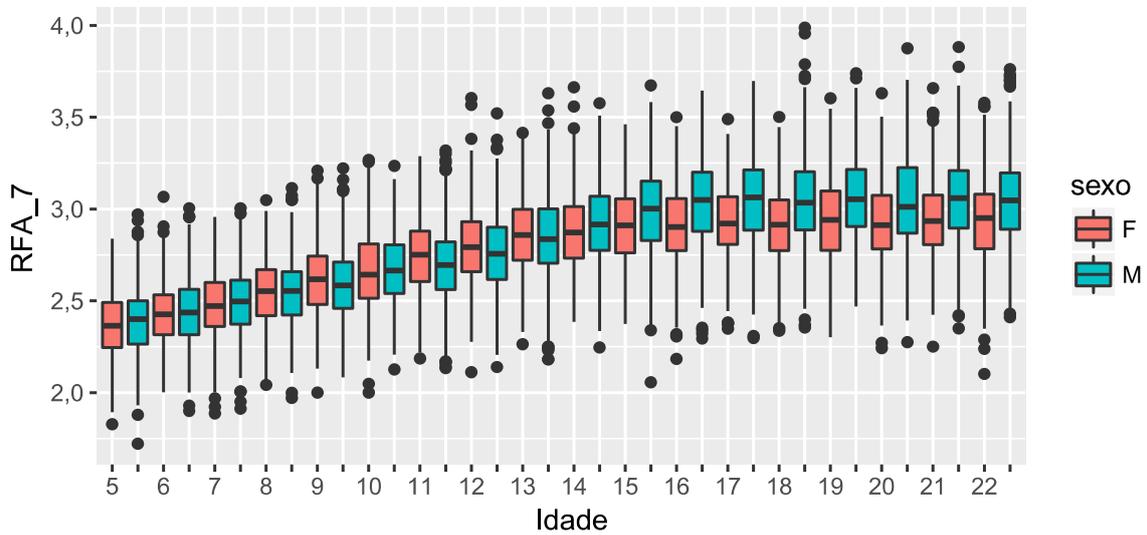
Distribuições da RFA_104 por Sexo e Idade

idades de 5 até 22 anos



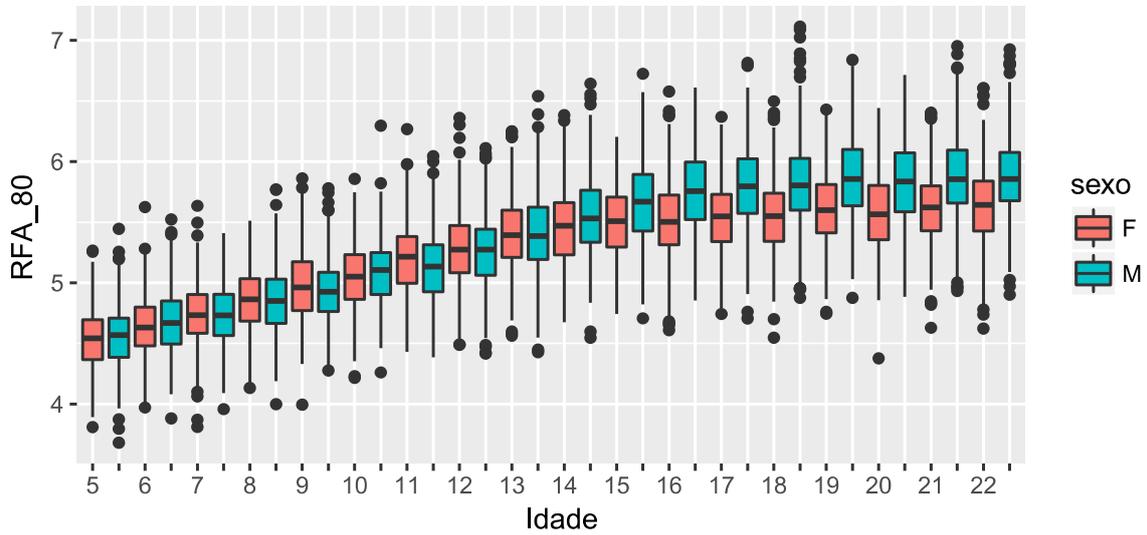
Distribuições da RFA_7 por Sexo e Idade

idades de 5 até 22 anos



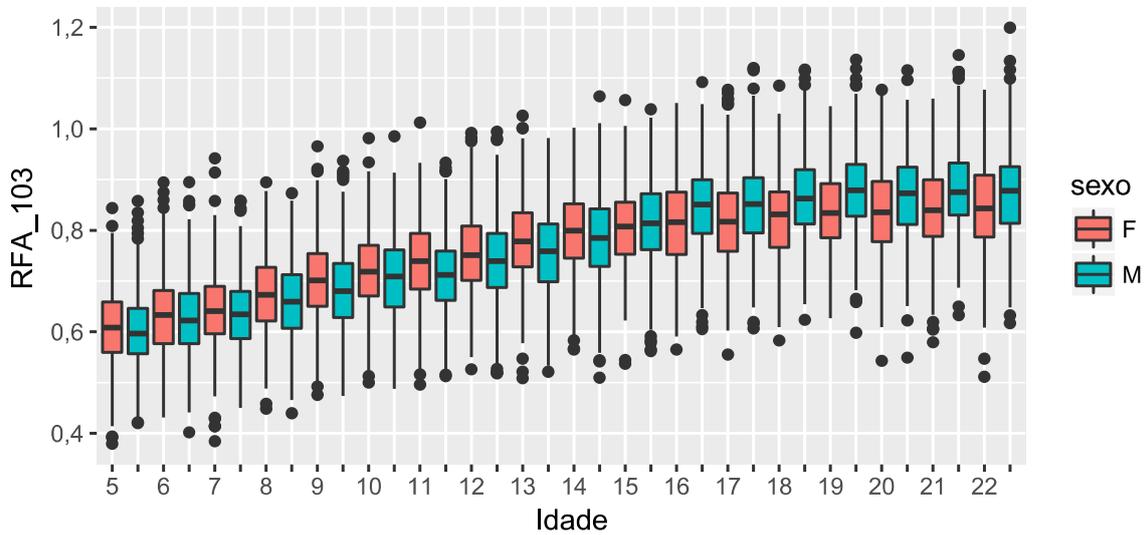
Distribuições da RFA_80 por Sexo e Idade

idades de 5 até 22 anos



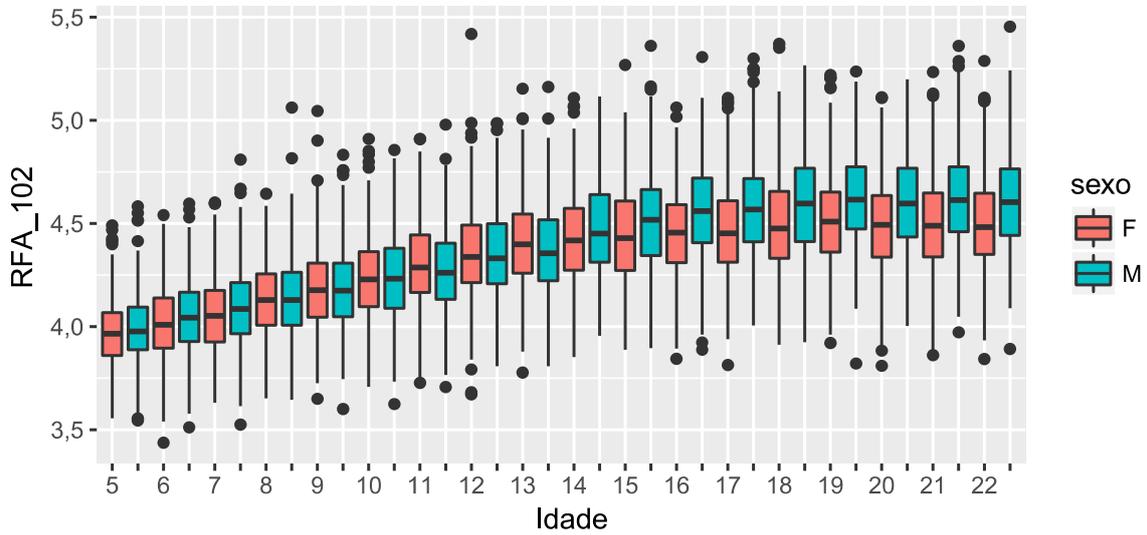
Distribuições da RFA_103 por Sexo e Idade

idades de 5 até 22 anos



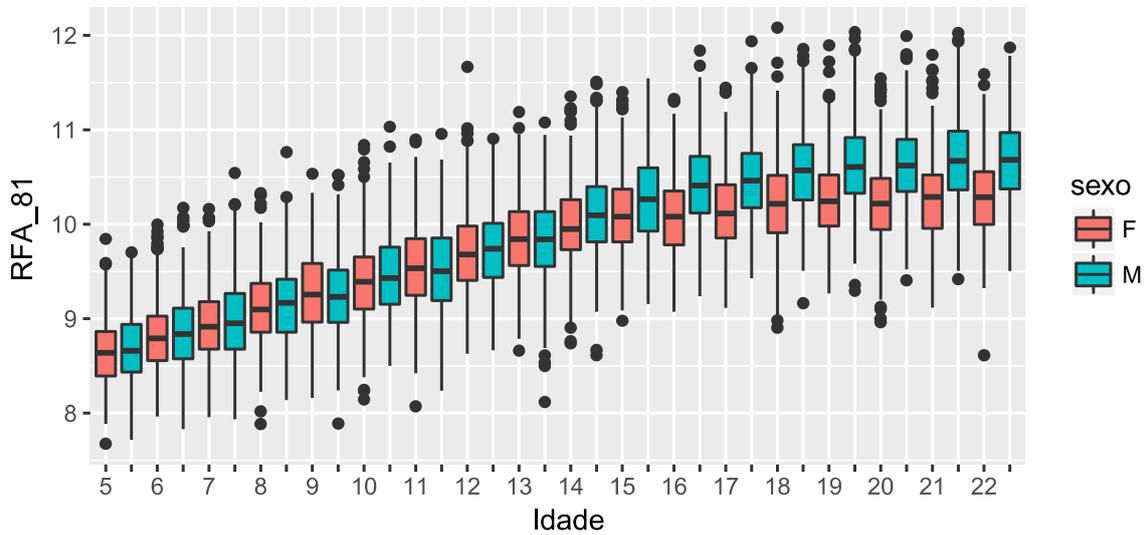
Distribuições da RFA_102 por Sexo e Idade

idades de 5 até 22 anos



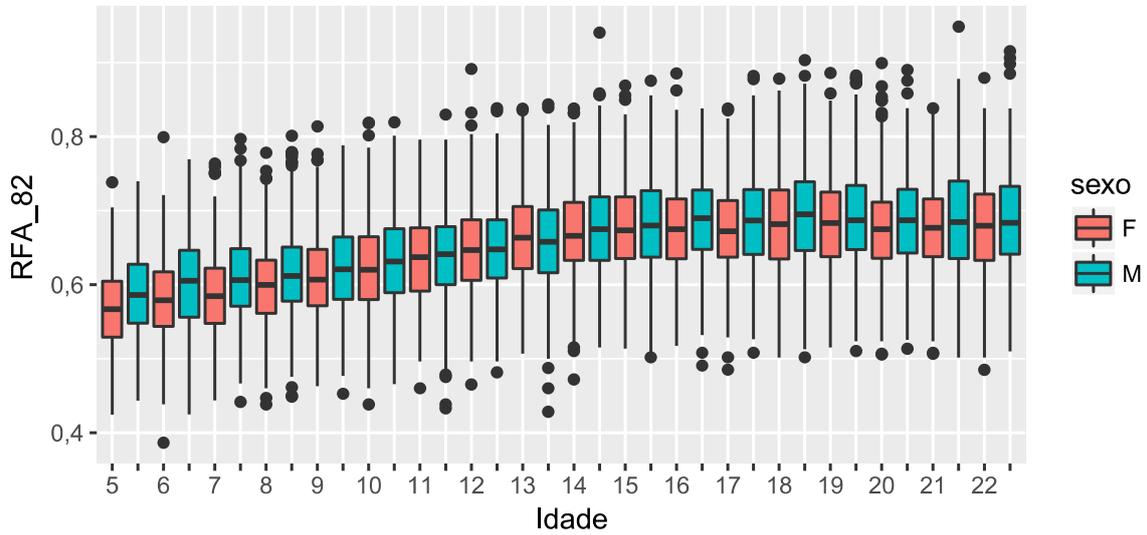
Distribuições da RFA_81 por Sexo e Idade

idades de 5 até 22 anos



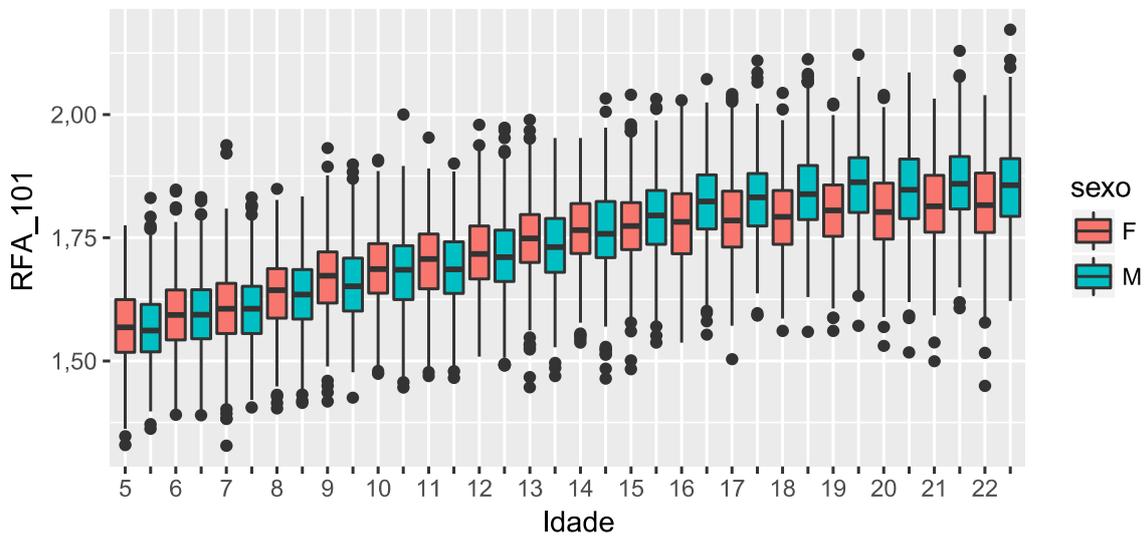
Distribuições da RFA_82 por Sexo e Idade

idades de 5 até 22 anos



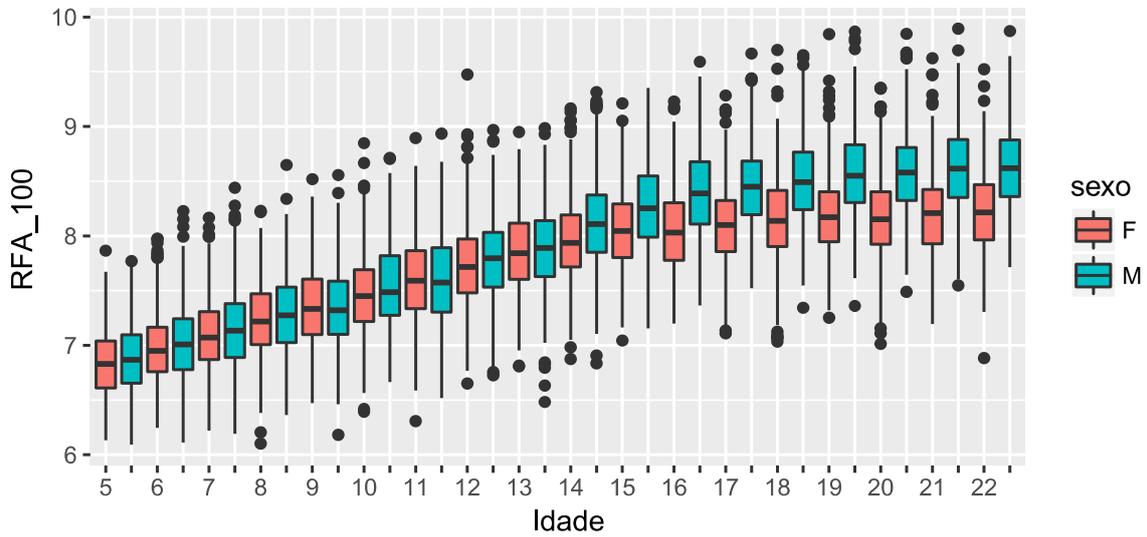
Distribuições da RFA_101 por Sexo e Idade

idades de 5 até 22 anos



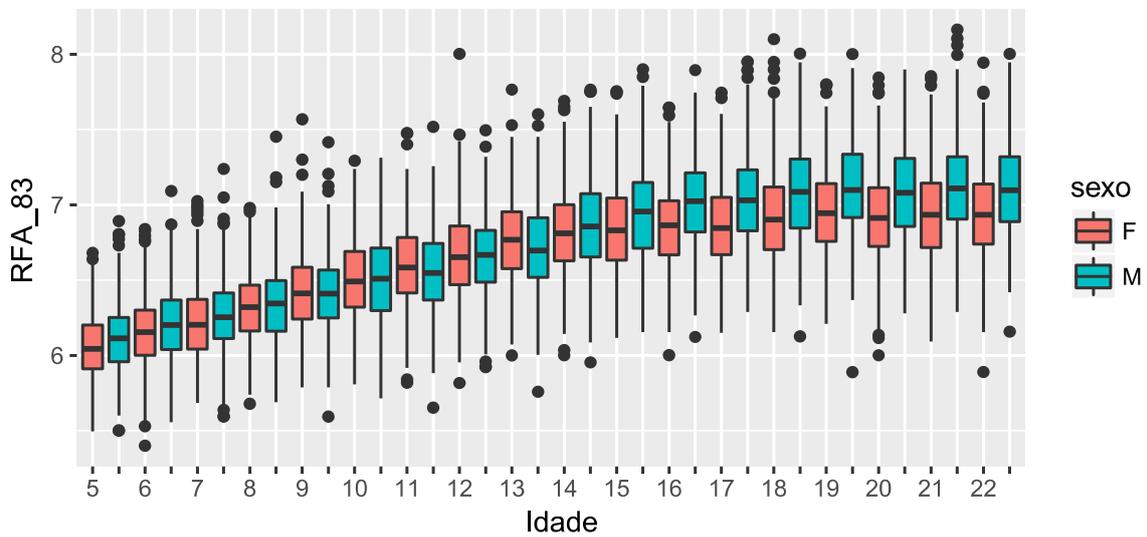
Distribuições da RFA_100 por Sexo e Idade

idades de 5 até 22 anos



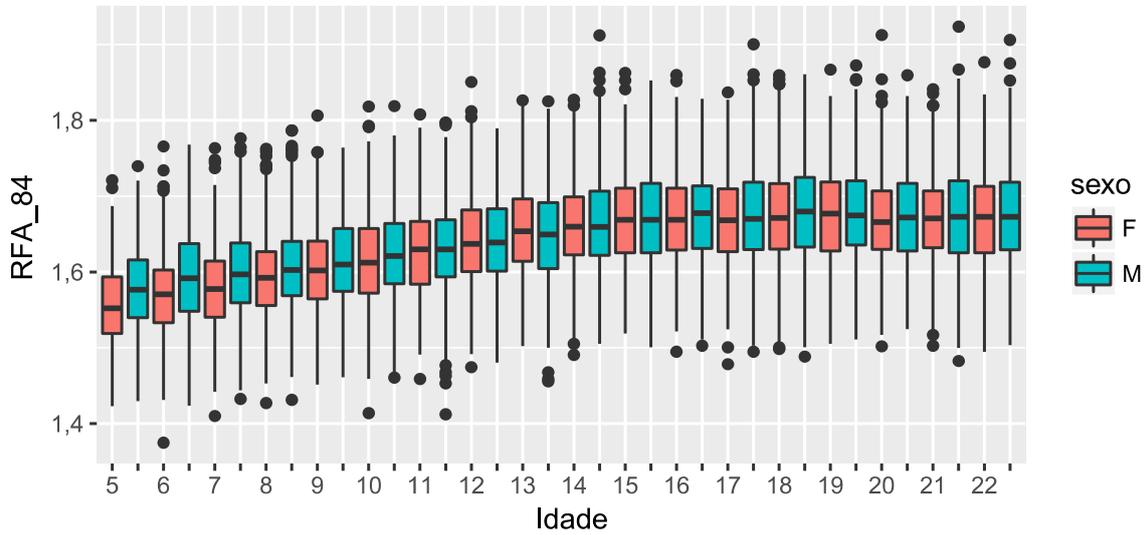
Distribuições da RFA_83 por Sexo e Idade

idades de 5 até 22 anos



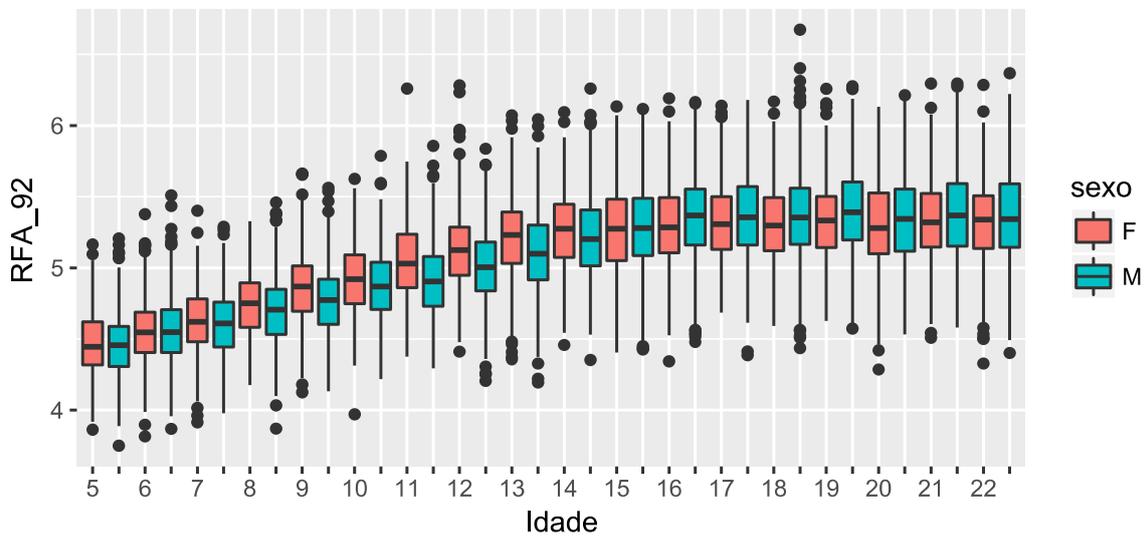
Distribuições da RFA_84 por Sexo e Idade

idades de 5 até 22 anos



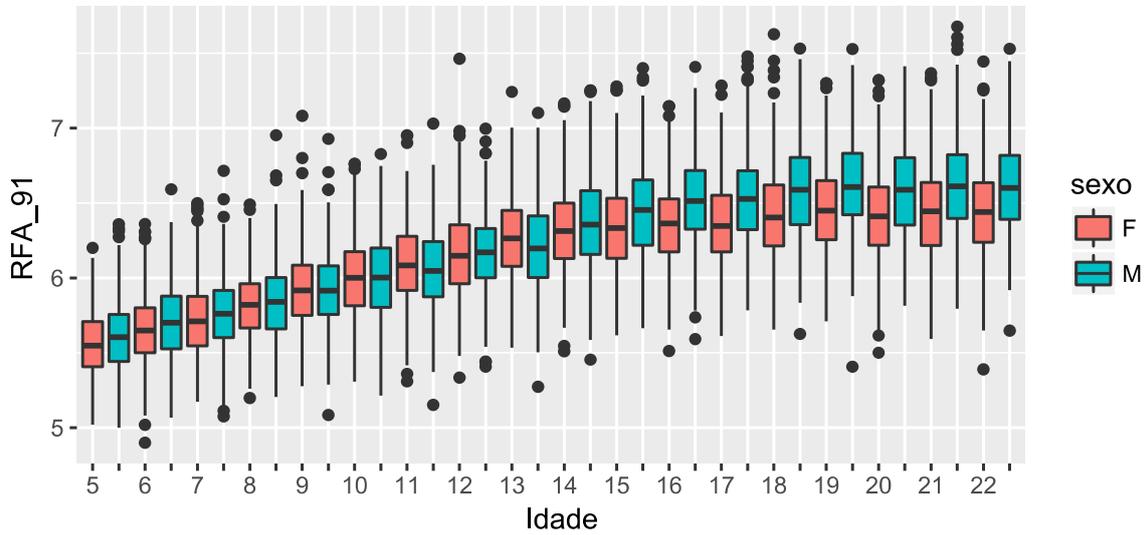
Distribuições da RFA_92 por Sexo e Idade

idades de 5 até 22 anos



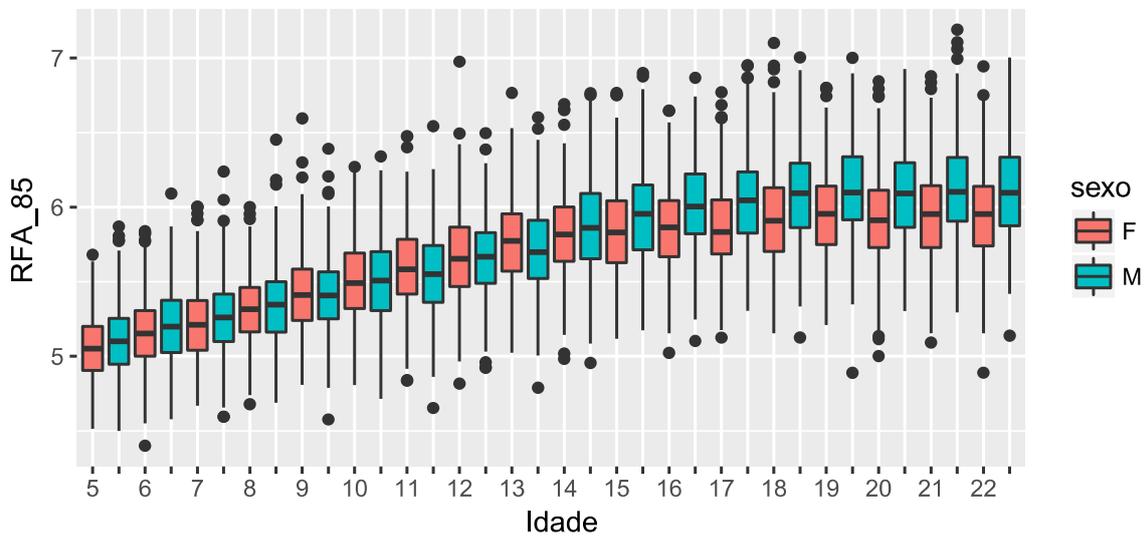
Distribuições da RFA_91 por Sexo e Idade

idades de 5 até 22 anos



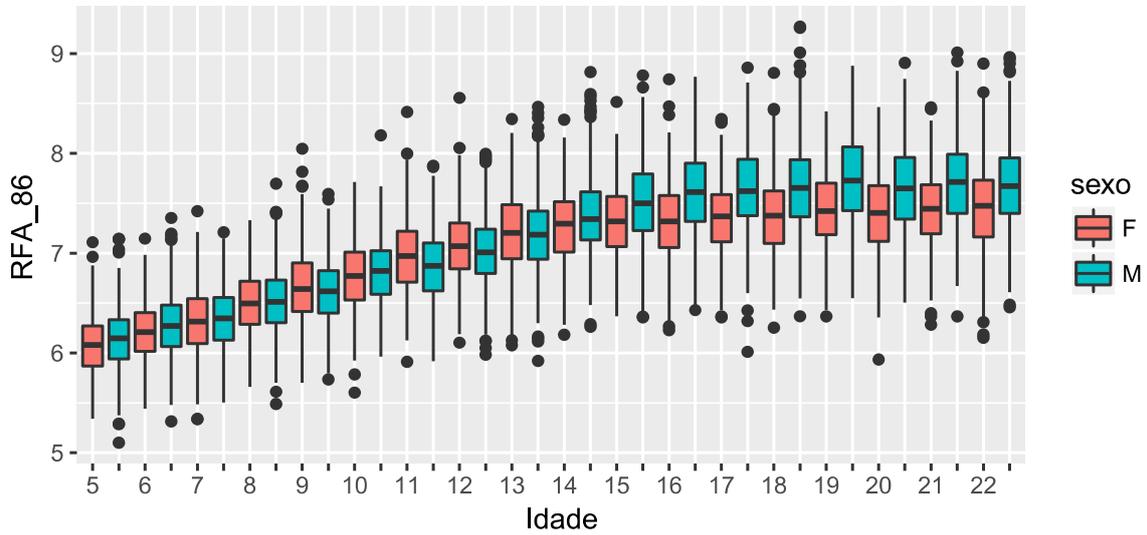
Distribuições da RFA_85 por Sexo e Idade

idades de 5 até 22 anos



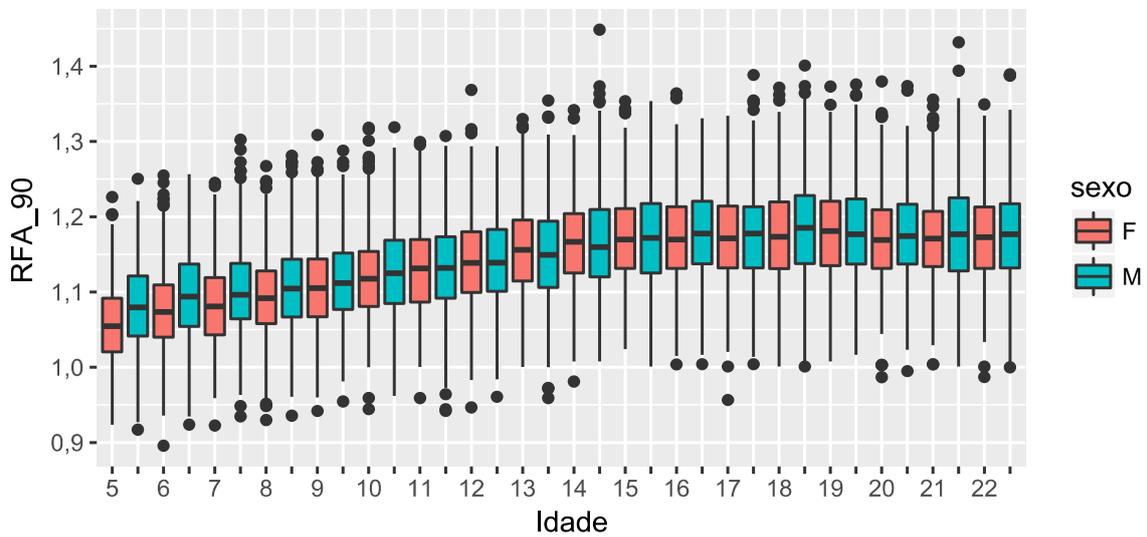
Distribuições da RFA_86 por Sexo e Idade

idades de 5 até 22 anos

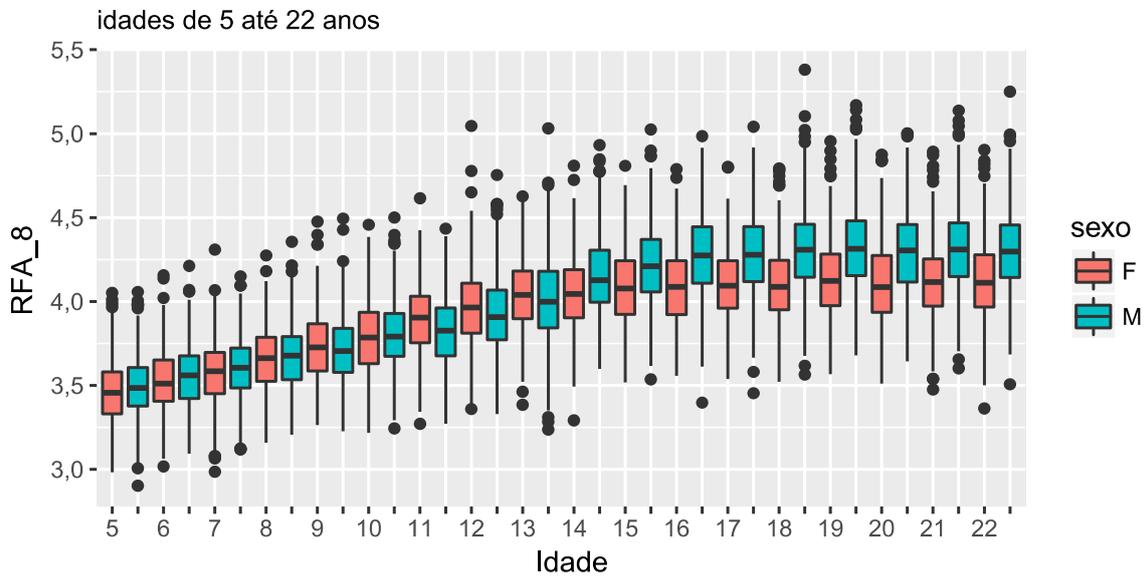


Distribuições da RFA_90 por Sexo e Idade

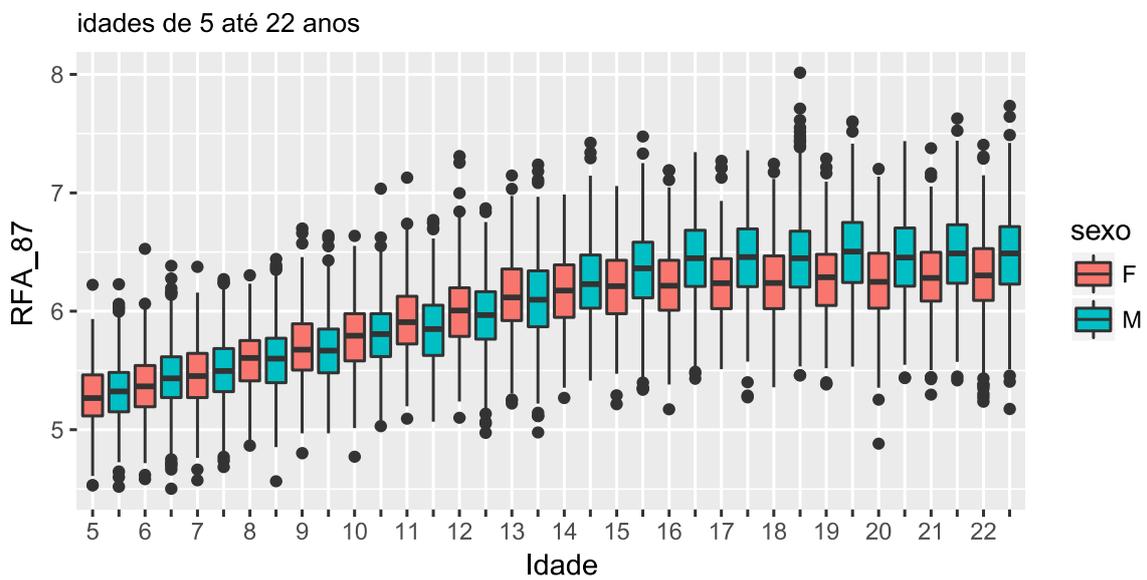
idades de 5 até 22 anos



Distribuições da RFA_8 por Sexo e Idade

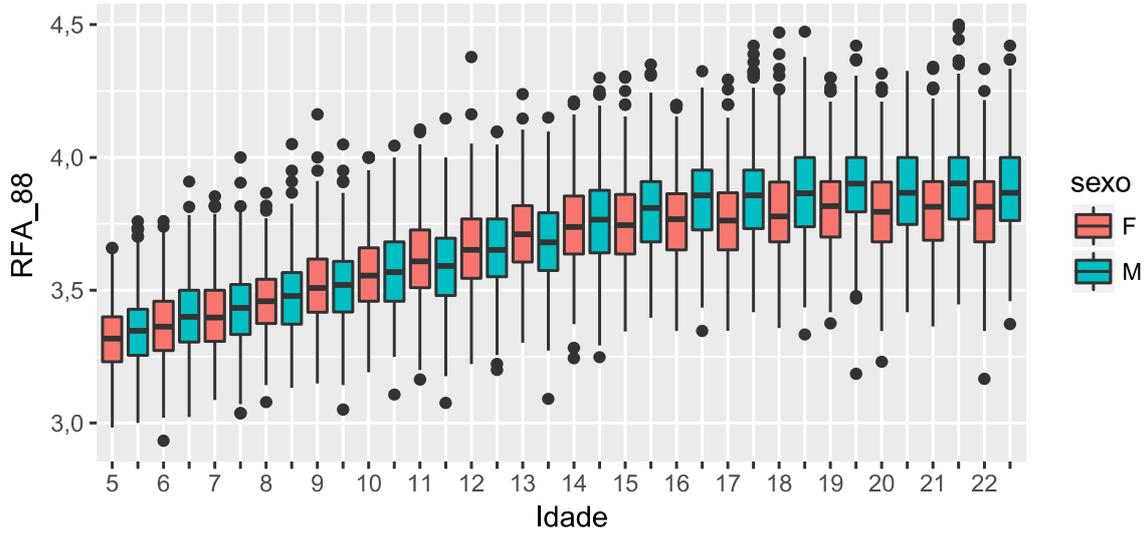


Distribuições da RFA_87 por Sexo e Idade



Distribuições da RFA_88 por Sexo e Idade

idades de 5 até 22 anos



Distribuições da RFA_89 por Sexo e Idade

idades de 5 até 22 anos

