

UNIVERSIDADE FEDERAL DE ALAGOAS
INSTITUTO DE COMPUTAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM COMPUTACIONAL DE
CONHECIMENTO

EDILEUZA VIRGINIO LEÃO

**MODELOS COMPUTACIONAIS BASEADOS EM APRENDIZAGEM DE MÁQUINA
PARA CLASSIFICAÇÃO DO CERATOCONE POR MEIO DOS SINAIS
BIOMECÂNICOS FORNECIDOS PELO OCULAR RESPONSER ANALYSER**

Maceió/AL

2013

EDILEUZA VIRGINIO LEÃO

**MODELOS COMPUTACIONAIS BASEADOS EM APRENDIZAGEM DE MÁQUINA
PARA CLASSIFICAÇÃO DO CERATOCONE POR MEIO DOS SINAIS
BIOMECÂNICOS FORNECIDOS PELO OCULAR RESPONSER ANALYSER**

Dissertação apresentada ao Programa de Pós-Graduação em Modelagem Computacional de Conhecimento da Universidade Federal de Alagoas (UFAL), como requisito para obtenção do título de mestre em modelagem computacional de conhecimento.

Orientador: Prof. Dr. Aydano Pamponet Machado

Co-orientador: Prof. Dr. João Marcelo de Almeida Gusmão Lyra.

Maceió/AL

2013

Catálogo na fonte
Universidade Federal de Alagoas
Biblioteca Central
Divisão de Tratamento Técnico
Bibliotecária: Fabiana Camargo dos Santos

L437m Leão, Edileuza Virginio.
Modelos computacionais baseados em aprendizagem de máquina para classificação do ceratocone por meio dos sinais biomecânicos fornecidos pelo Ocular Responser Analyser / Edileuza Virginio Leão. – 2013.
84 f. : il.

Orientador: Aydano Pamdonet Machado.
Coorientador: João Marcelo de Almeida Gusmão Lyra.
Dissertação (Mestrado em Modelagem Computacional do Conhecimento) – Universidade Federal de Alagoas. Instituto de Computação. Maceió, 2013.

Bibliografia: f. 67-70.
Apêndices: f. 71-84.

1. Aprendizagem de máquina. 2. Ceratocone – Diagnóstico.
3. Córnea – Biomecânica. I. Título.

CDU: 004.85:616-07



UNIVERSIDADE FEDERAL DE ALAGOAS/UFAL
Programa de Pós-Graduação em Modelagem Computacional de Conhecimento
Avenida Lourival Melo Mota, Km 14, Bloco 09, Cidade Universitária
CEP 57.072-900 – Maceió – AL – Brasil
Telefone: (082) 3214-1364



Membros da Comissão Julgadora da Dissertação de Mestrado de Edileuza Virgíno Leão, intitulada: “Modelos computacionais baseados em aprendizagem de máquina para classificação do ceratocone por meio dos sinais biomecânicos fornecidos pelo Ocular Responder Analyser”, apresentada ao Programa de Pós-Graduação em Modelagem Computacional de Conhecimento da Universidade Federal de Alagoas em 1º de novembro de 2013, às 14h30min, no auditório do Instituto de Computação – IC/UFAL.

COMISSÃO JULGADORA

Prof. Dr. Aydano Pamponet Machado

UFAL – Instituto de Computação

Orientador

Prof. Dr. João Marcelo de Almeida Gusmão Lyra

UNCISAL – Universidade Estadual de Ciências da Saúde de Alagoas

Orientador

Prof. Dr. Leandro Dias da Silva

UFAL – Instituto de Computação

Examinador

Dr. Renato Ambrósio Júnior

UNIFESP – Pós-Graduação em Oftalmologia e Ciências Visuais

Examinador

Maceió, novembro de 2013.

A força maior, Deus, que me deu a oportunidade e a disposição para execução deste trabalho.

AGRADECIMENTOS

Aos Prof. Dr. Aydano Pamponet Machado e ao Prof. Dr. João Marcelo de Gusmão Lyra, pela orientação, direcionamento e paciência.

A Paulo Rogério Barbosa, meu esposo e companheiro, pela motivação, apoio e compreensão em todas as horas necessárias para minha dedicação.

A Guilherme Ribeiro e Bruna Vieira Oliveira Carvalho Ventura, pela disposição em ajudar em todos os momentos.

A minha família pela estrutura sólida que me ajudou a chegar até aqui.

Aos amigos de grupo de estudo BrAln pelo apreço.

Aos amigos de curso.

RESUMO

O presente trabalho destina-se a desenvolver modelos computacionais baseados em inteligência artificial para detecção do ceratocone, criando métodos capazes de prever a presença do ceratocone utilizando aprendizagem de máquina. Estes modelos utilizaram dados biomecânicos da córnea, proveniente dos sinais de aplanção e pressão do exame Ocular Response Analyzer (ORA). O objetivo é construir modelos computacionais para auxiliar na decisão do cirurgião refrativo entre realizar ou não a cirurgia em casos susceptíveis. Os modelos foram criados utilizando árvore de decisão e redes neurais dos tipos MLP e RBF e também processamento de sinais wavelet. O experimento foi dividido em duas fases: a primeira para conhecer e entender os sinais, identificando as características e regiões mais importantes; a segunda utilizando o processamento de sinais wavelet para extrair a informação relevante do sinal. Os vários modelos desenvolvidos em ambas as fases foram estudados e comparados. Os melhores resultados encontrados foram: para a taxa total de acerto 93,03%, taxa de sensibilidade 93,95% e taxa de especificidade 99,26%. Tendo como conclusão que os modelos desenvolvidos podem contribuir com o cirurgião refrativo em sua decisão no diagnóstico do ceratocone grau I e II.

Palavras-chave: Aprendizagem de máquina. Ceratocone. Biomecânica da córnea.

ABSTRACT

This work aims to develop computational models based on artificial intelligence to detect keratoconus, creating methods to predict the presence of keratoconus using machine learning. These models used corneal biomechanical data, from the signs of applanation and pressure the Ocular Response Analyzer exam (ORA). The goal is to build computational models to help the refractive surgeon decide between performing surgery or not in cases susceptible. The models were created using neural networks the types of MLP and RBF and tree decision and also Wavelet signal processing. The experiment was divided into two phases: the first to know and understand the signals identifying the most important features and regions, and the second using the wavelet signal processing to extract the relevant information signal. The various models developed in two phases were studied and compared. The best results were: for total accuracy rate of 93.03%, 93.95% rate of sensitivity and specificity rate of 99.26%. The conclusion is that the developed models can contribute to the refractive surgeon in his decision in the diagnosis of keratoconus grade I and II.

Keywords : Machine learning . Keratoconus . Biomechanics of the cornea.

LISTA DE FIGURAS

Figura 1 – Olho com ceratocone avançado.	17
Figura 2 – Aparelho Ocular Response Analyzer.	21
Figura 3 – Passo 1 do exame ORA.	22
Figura 4 – Primeiro momento da curva do exame ORA.	22
Figura 5 – Passo 2 do exame ORA.	22
Figura 6 – Segundo momento da curva do exame ORA.	23
Figura 7 – Passo 3 do exame ORA.	23
Figura 8 – Terceiro momento da curva do exame ORA.	23
Figura 9 – Passo 4 do exame ORA.	24
Figura 10 – Quarto momento da curva do exame ORA.	24
Figura 11 – Passo 5 do exame ORA.	25
Figura 12 – Quinto momento da curva do exame ORA.	25
Figura 13 – Passo 6 do exame ORA.	25
Figura 14 – Sexto momento da curva do exame ORA.	26
Figura 15 – Picos são significativos para detecção de ceratocone.	26
Figura 16 – Hierarquia de aprendizagem.	28
Figura 17 – Exemplo de árvore de decisão	29
Figura 18 – Neurônio artificial de McCulloch e Pitts.	30
Figura 19 – Matriz de confusão para duas classes.	35
Figura 20 – Decomposição Wavelet.	39
Figura 21 – Árvore de decomposição wavelet.	40
Figura 22 – Alguns tipos de wavelets.	41
Figura 23 – Matriz de confusão após processamento da rede neural MLP no conjunto 8.	57
Figura 24 – Matriz de confusão após processamento da rede neural MLP no conjunto 17.	58
Figura 25 – Matriz de confusão após processamento da rede neural RBF no conjunto 8.	58
Figura 26 – Matriz de confusão após processamento da rede neural RBF no conjunto 25.	58
Figura 27 – Matriz de confusão após processamento da rede neural MLP da aproximação 4 com wavelet do tipo Haar no Conjunto 8.	59
Figura 28 – Matriz de confusão após processamento da rede neural MLP da aproximação 3 com wavelet do tipo Haar do conjunto 17.	59
Figura 29 – Matriz de confusão após processamento da rede neural MLP da aproximação 1 com wavelet do tipo Db10 no conjunto 8.	60
Figura 30 – Matriz de confusão após processamento da rede neural MLP da aproximação 1 com wavelet do tipo Coif5 no conjunto 8.	60
Figura 31 – Matriz de confusão após processamento da rede neural MLP da aproximação 3 com wavelet do tipo Coif1 no conjunto 25.	60

Figura 32 – Matriz de confusão após processamento da rede neural RBF da aproximação 3 com wavelet do tipo Coif1 no conjunto 8.

LISTA DE QUADROS

Quadro 1 – Conjuntos referente ao sinal de pressão.	45
Quadro 2 - Conjuntos referente ao sinal da aplanção.	46
Quadro 3 – Conjuntos referente a aplanção como pontos .	46
Quadro 4 – Conjuntos referente ao Pico 1 do sinal da aplanção.	47
Quadro 5 – Conjuntos referente ao Pico 2 do sinal da aplanção.	47
Quadro 6 – Conjuntos referente aos dois sinais: pressão e aplanção.	48
Quadro 7 – Conjuntos referente aos dois sinais focando o pico 1 da aplanção.	49
Quadro 8 – Conjuntos referente aos dois sinais focando o pico 2 da aplanção.	50
Quadro 9 – Outros conjuntos referente aos dois sinais.	51
Quadro 10 – Conjunto 8 destaque.	53
Quadro 11 – Decomposição wavelet Haar do conjunto 8.	53
Quadro 12– Decomposição wavelet Coiflets 1, Coiflets 5, Daubechies 5 e Daubechies 10 do conjunto 8.	54
Quadro 13 – Conjuntos 17 e 25 destaques contendo pontos da pressão.	55
Quadro 14 – Decomposições wavelets conjuntos 17.	55

LISTA DE TABELAS

Tabela 1 – Classificação de Krumeich.	19
Tabela 2 – Medidas de desempenho da matriz de confusão.	35

SUMÁRIO

1	INTRODUÇÃO	13
1.1	Um Modelo Computacional para Auxiliar na Triagem de Pacientes para a Cirurgia Refrativa	13
1.1.1	A triagem de pacientes para a cirurgia refrativa	13
1.1.2	Criação de um modelo computacional para auxiliar na detecção de ceratocone com base em parâmetros biomecânicos	15
2	CERATOCONE E SEU DIAGNÓSTICO	17
2.1	Ceratocone	17
2.2	Classificação do Ceratocone	18
2.3	Diagnóstico do Ceratocone	19
2.3.1	Topografia de córnea	19
2.3.2	Tomografia de córnea	20
2.3.3	Ocular responser analyser	20
3	INTELIGÊNCIA ARTIFICIAL BASEADA EM APRENDIZAGEM DE MÁQUINA	27
3.1	Aprendizagem de Máquina	27
3.1.1	Indução	27
3.1.2	Modelos supervisionados ou preditivos	28
3.1.2.1	Árvore de decisão	29
3.1.2.2	Rede neural	30
3.1.2.2.1	Rede perceptron de múltiplas camadas	31
3.1.2.2.2	Rede de função de base radial (RBF)	31
3.1.3	Conjunto de dados	32
3.1.3.1	Técnicas de pré-processamento	32
3.1.4	Aprendizagem automática de classificadores	34
3.1.4.1	Validação cruzada	34
3.1.4.2	Matriz de confusão	35
4	PROCESSAMENTO DE SINAIS	37
4.1	Wavelet	37
4.2	Transformada Wavelet	38
4.3	Decomposição Wavelet	39
4.4	Compressão de Sinais	40

4.5	Tipos de Wavelets	40
5	CONSTRUÇÃO DO MODELO COMPUTACIONAL	42
5.1	Estudo Geral dos Sinais de Pressão e Aplanção (Fase 1).....	44
5.2	Decomposição Wavelet (Fase 2)	52
6	RESULTADOS E DISCUSSÕES	57
6.1	Melhores Resultados Fase 1 – Estudo Geral dos Sinais de Pressão e Aplanção	57
6.2	Melhores Resultados Fase 2 – Decomposição Wavelet	59
7	CONCLUSÃO E TRABALHOS FUTUROS	62
	REFERÊNCIAS.....	64
	APÊNDICE A – Todos os Resultados Encontrados	68

1 INTRODUÇÃO

A ideia de unir informática e saúde já é bem antiga, várias áreas da computação podem auxiliar os processos diários da medicina e os impactos positivos dessa união são cada vez mais presentes. Isso vem acontecendo desde as formas mais simples, tal como o armazenamento de dados por meio de sistemas de informações, chegando até aos hardwares desenvolvidos para medicina nuclear. Esta união tem contribuído de forma significativa no processo do diagnóstico médico. (DEPARTAMENTO DE INFORMÁTICA EM SAÚDE DA UNIFESP, 2013)

No Brasil, o desenvolvimento da especialidade informática em saúde é crescente. Vários grupos de pesquisa, universidades e o próprio governo federal se dedicam a iniciativas nesta área. Um exemplo disso é a criação de cursos de graduação, pós-graduação e desenvolvimento de pesquisas nas diversas subáreas que abrangem a informática em saúde. (SOCIEDADE BRASILEIRA DE INFORMÁTICA EM SAÚDE, 2013)

Enfatizando a informática médica em oftalmologia é possível ressaltar inúmeras aplicações, desde a utilização da computação gráfica para auxiliar na formação acadêmica até hardwares para refração. Mesmo com todo o avanço já conseguido, ainda existem muitos problemas na oftalmologia que precisam ser otimizado utilizando a computação, um deles é o foco deste trabalho.

1.1 Um Modelo Computacional para Auxiliar na Triagem de Pacientes para a Cirurgia Refrativa

1.1.1 A triagem de pacientes para a cirurgia refrativa

Com o desenvolvimento tecnológico alcançado nas duas últimas décadas, a cirurgia refrativa utilizada para correção de miopia, astigmatismo e hipermetropia, se tornou um procedimento seguro e habitual, sendo realizado em larga escala, permitindo a vários pacientes independência de óculos ou lentes de contato. Mas conseqüente ao aumento do uso da técnica, cresceu também a quantidade de complicações pós-cirúrgicas (PEREIRA;FORSETO;NOSE, 2001). Estas complicações exigem dos médicos uma seleção criteriosa dos pacientes a fim de evitar conseqüências indesejáveis.

Os critérios de seleção para a cirurgia variam de acordo com a técnica utilizada, mas os pacientes devem, de forma geral, ter mais de 18 anos e possuir uma refração estável por pelo menos 1 ano (ANG, 2009). Além da idade e estabilidade refracional, existem patologias corneanas que são contraindicações relativas deste procedimento, um exemplo disso é o ceratocone (MEDEIROS, 2011).

O ceratocone é um astigmatismo irregular corneal que provoca queda da acuidade visual. Estágios iniciais são corrigidos com óculos ou lente de contato, mas estágios avançados apenas com transplante de córnea (CONSELHO REGIONAL DE ÓPTICA E OPTOMETRIA, 2013). O ceratocone é caracterizado pela degeneração da córnea, parte transparente e externa do olho, que por perder sua resistência é abaulada para frente como um cone, essa protuberância é chamada de ectasia (KASTEL, 1996 apud LIMA, 2000).

O tipo de ectasia iatrogênica é a mais temida pelos cirurgiões refrativos. Esta consiste em uma complicação rara que acomete a córnea após intervenção cirúrgica (CONSELHO REGIONAL DE ÓPTICA E OPTOMETRIA, 2013). Entende-se que durante a cirurgia refrativa uma extração excessiva de parte da córnea a torna mais fraca, não resistindo à pressão intraocular e levando ao seu afinamento e deformidade (BINDER, 2007).

A cirurgia refrativa pode acelerar a degeneração da córnea quando há presença do ceratocone, fazendo a protuberância que ainda não existia, que estava em seu estágio leve se desenvolver, estes são chamados de casos suscetíveis. Não há como prever esse quadro de ectasia corneal antes da cirurgia, há apenas situações que podem servir como sinais para o oftalmologista (CONSELHO REGIONAL DE ÓPTICA E OPTOMETRIA, 2013).

Então como identificar qual córnea desenvolverá ectasia? Esse desafio faz parte do dia a dia do cirurgião refrativo. Os métodos de análise da córnea que mais dão suporte ao médico para localizar os casos de maior risco são baseados em imagem como a topografia e a tomografia (VALBON et al,2012). As ferramentas de detecção de ceratocone estão sendo melhoradas a cada dia, mas mesmo com tal avanço ainda existem casos que não são detectados por imagem e a resposta pode estar no estudo de outras técnicas de análise da córnea como as que se baseiam na biomecânica (KLEIN,S.R. et al. apud MEDEIROS, 2011).

A cirurgia refrativa causa impacto na estrutura biomecânica da córnea, impacto que pode levar ao desenvolvimento da ectasia. (SEILER,T.;

KOUFALA,K.;RICHTER,G. e AMOILS,S.P. et al. apud MEDEIROS, 2011). O estudo da estrutura biomecânica da córnea antes da cirurgia pode revelar um novo caminho para detecção de ectasia antes da cirurgia refrativa.

1.1.2 Criação de um modelo computacional para auxiliar na detecção de ceratocone com base em parâmetros biomecânicos

Entendendo que as propriedades biomecânicas da córnea podem contribuir na detecção de casos suscetíveis e que esta detecção é decisiva para a realização da cirurgia refrativa, o objetivo neste trabalho é contribuir na tomada de decisão do médico quanto à realização de cirurgia em pacientes suspeitos de desenvolverem ectasia utilizando estas propriedades.

Para isso será apresentado que métodos são utilizados para essa detecção e também será detalhado o meio de obtenção dos parâmetros biomecânicos da córnea, utilizado neste trabalho, para que seja possível analisá-los posteriormente. Estes pontos serão discutidos no capítulo 2 deste trabalho: “CERATOCONE E SEU DIAGNÓSTICO”.

Conhecendo os parâmetros biomecânicos da córnea a serem estudados será possível a criação de um modelo computacional que possa analisá-los, utilizando a computação para analisar os parâmetros e definir um modelo, um padrão, que será capaz de predizer com certa precisão a predisposição para ceratocone.

Este modelo computacional será baseado em aprendizagem de máquina, vertente da computação que pretende fazer o computador aprender com a experiência, é uma área da inteligência artificial.

O capítulo 3: “INTELIGÊNCIA ARTIFICIAL BASEADA EM APRENDIZAGEM DE MÁQUINA” abordará estes temas no intuito de explicar ao leitor com mais detalhes o que é um modelo computacional baseado em aprendizagem de máquina.

O modelo desenvolvido também utilizará técnicas de processamento de sinais, pois será visto que as propriedades biomecânicas da córnea analisadas são apresentadas na forma de sinal, o capítulo 4 “PROCESSAMENTO DE SINAIS” detalha sobre essas técnicas de processamento.

Então, reafirmando, neste trabalho serão criados modelos computacionais baseados em aprendizagem de máquina utilizando processamento de sinais que sejam capazes de analisar os parâmetros biomecânicos da córnea e que possam

contribuir no auxílio do cirurgião refrativo quanto à decisão da realização da cirurgia em casos suscetíveis.

Os passos para a criação deste modelo serão apresentados no capítulo 5: “CRIAÇÃO DO MODELO COMPUTACIONAL”, os resultados de sua aplicação podem ser vistos no capítulo 6: “RESULTADOS E DISCUSSÕES”, e a conclusão do trabalho está no último capítulo.

2 CERATOCONE E SEU DIAGNÓSTICO

Este capítulo se destina a apresentar uma breve definição de ceratocone, sua classificação, e como atualmente é feito o seu diagnóstico. Bem como alguns detalhes sobre o aparelho utilizado neste trabalho para obtenção de parâmetros biométricos da córnea.

2.1 Ceratocone

A córnea, parte transparente e externa do olho, mantém de forma mecânica e química uma barreira entre o interior do olho e o meio ambiente e também possui importante função refrativa. (WARING, 1984; KLYCE & BEUERMAN, 1988 apud LYRA, 2006)

Quando a córnea é acometida por doenças que levam à redução da transparência ou à alteração de sua curvatura, há uma diminuição significativa da visão. Uma das principais causas dessas alterações é o ceratocone. (CUNHA & HOFLING-LIMA, 1997 apud LYRA, 2006)

O ceratocone é uma alteração da forma (distrofia) da córnea não inflamatória, normalmente afeta ambos os olhos, porém somente um olho pode ser acometido inicialmente, devido a um afilamento localizado, com conseqüente deslocamento ou protrusão anterior, ectasia, na qual a córnea assume uma curvatura cônica (Figura 1). (KASTEL, 1996 apud LIMA, 2000)

Figura 1 – Olho com ceratocone avançado.



Fonte: CONSELHO BRASILEIRO DE OFTALMOLOGIA, 2013.

Como citado pelo Conselho Brasileiro de Oftalmologia (CONSELHO BRASILEIRO DE OFTALMOLOGIA, 2013):

[...] Trata-se de condição rara, encontrada em todas as raças, nas diferentes partes do mundo, com prevalência que varia de 4 a 600 casos por 100.000 indivíduos. História familiar está presente de 6 a 8% dos casos, sugerindo herança familiar. Seu aparecimento mais comum ocorre na puberdade, geralmente entre os 13 e os 18 anos de idade, progride por aproximadamente 6 a 8 anos e, após, tende a permanecer estável.

2.2 Classificação do Ceratocone

Para este trabalho será necessário explorar o tema classificação de ceratocone, pois o objetivo é detectar estágios iniciais da patologia, onde ainda não houve progresso da ectasia. Então, como são definidos estes estágios? É o que veremos a seguir.

A classificação do ceratocone para a oftalmologia é de grande importância, pois em estágios diferentes da doença são tomadas condutas distintas. Existem vários meios de classificação do ceratocone: considerando os achados clínicos, biomicroscópicos, avaliação do nível visual, curvatura corneana (MIRANDA E CAMPOS, 2004 apud LYRA,2006) e padrões identificados pela topografia da córnea (SINJAB,2012).

Em relação aos padrões identificados pela topografia da córnea existem várias formas de classificação: através de mapas de elevação, mapas de espessura e mapas de curvatura. O mapa de curvatura anterior sagital apresenta várias irregularidades da córnea e se deve dá uma atenção especial, pois alguns sinais do mapa indicam presença de ceratocone. (SINJAB,2012)

A classificação de Krumeich que utiliza o mapa de curvatura anterior sagital foi escolhida, pois esta define 4 graus ou estágios do ceratocone, onde os dois estágios iniciais estão em pequeno grau de desenvolvimento da ectasia. Como se pretende detectar casos suscetíveis estes são os casos que mais se aproximam deste padrão.

A Tabela 1 descreve essa classificação apresentando a ceratometria (medida da curvatura corneal) média, a espessura da córnea, o equivalente esférico e o estado da córnea em relação a cicatrizes para cada um dos graus da classificação.

Tabela 1 – Classificação de Krumeich.

Gravidade	Ceratometria média Km	Espessura da córnea	Equivalente esférico (em dioptrias)	Estado da córnea
1	<48	>500	<-5	Sem cicatrizes centrais
2	48 – 53	400 – 500	[-5,-8]D	Sem cicatrizes centrais
3	54 – 55	200 – 400	>-8D	Sem cicatrizes centrais
4	>55	<200	Não mensurada	Com cicatrizes centrais

Fonte: Adaptado de P. 39 SINJAB,2012.

2.3 Diagnóstico do Ceratocone

Definido o que é ceratocone e a classificação que será usada neste trabalho, serão apresentados exames utilizados para a detecção de ceratocone que são baseados em imagem: a topografia e a tomografia da córnea. Por fim será discutido o exame ORA que estuda a biomecânica da córnea, analisado neste trabalho.

2.3.1 Topografia de córnea

A topografia é a ciência que descreve ou representa as características de certo local. Diante desta definição a topografia corneal é a descrição ou representação pormenorizada da superfície anterior da córnea. Considerada uma técnica de imagem não invasiva que estuda a superfície corneana utilizando mapas de curvatura a topografia corneal pode contribuir na melhora da capacidade do diagnóstico médico e permitir uma melhor escolha da conduta médica (NAJJAR apud MARTINS;OLIVEIRA,2011).

A topografia, em conjunto com a aprendizagem de máquina, já foi utilizada para detecção de ceratocone, alguns exemplos de trabalhos são: PENSIERO e ACCARDO (2002) de tema: Sistema baseado em redes neurais para detecção de ceratocone inicial de topografia corneana (do inglês: Neural network-based system for early keratoconus detection from corneal topography). Tal trabalho concluiu que os parâmetros topográficos da córnea podem contribuir na detecção de ceratocone.

Outro trabalho de SMOLEK, KLYCE e KARON (2005) com tema: A triagem de pacientes com o navegador da córnea (do inglês: Screening patients with the

corneal navigator). Este trabalho utilizou redes neurais para reconhecer corretamente topografias normais.

2.3.2 Tomografia de córnea

A tomografia da córnea é um exame não invasivo que utiliza uma câmera de alta velocidade (Câmera Scheimpflug), a qual faz cortes transversais da córnea, em diversas incidências, criando assim um mapa em 3D da córnea.

O diagnóstico mais moderno utilizado no dia a dia do cirurgião até o início do desenvolvimento deste trabalho para a detecção de ceratocone é o parâmetro titulado como BAD (Belin Ambrósio Display) (BELIN,2007) (BELIN;AMBROSIO, 2010), onde o grupo BrAI – Brazilian Study Group of Artificial Intelligence and Corneal Analysis, grupo que desenvolve este trabalho, participou da última versão do BAD, trabalho que gerou participações em capítulos de livros e diversos trabalhos publicados (LYRA, 2012).

Outros trabalhos já associaram a tomografia à aprendizagem de máquina para detecção de ceratocone, um exemplo de trabalho é: SOUZA e outros de 2010 com tema: “Evaluation of machine learning classifiers in keratoconus detection from orbscan II examinations” que utiliza entre outros a Rede Neural *perceptron* multicamada e a rede de base de função radial (RBF).

Os resultados deste trabalho de Souza et al. (2010) sugerem que os classificadores testados com dados do Orbscan II poderia representar técnicas úteis para detecção de ceratocone.

2.3.3 Ocular responder analyser

É possível perceber que os exames de imagem tais como a topografia e a tomografia, já foram estudados em conjunto com a aprendizagem de máquina para detecção de ceratocone, mas não foram encontrados trabalhos relacionados ao estudo de exames que observam as propriedades biomecânicas da córnea.

O primeiro e único aparelho comercializado até o início deste trabalho capaz de capturar essas propriedades se chama *Ocular Response Analyzer*®. O *Ocular Response Analyzer* (ORA), Figura 2, foi desenvolvido para calcular as propriedades biomecânicas do tecido corneal *in vivo* utilizando o meio de força e deslocamento.

Figura 2 – Aparelho Ocular Response Analyzer.



Fonte: REICHERT TECHNOLOGIES, 2013.

Capaz de medir a pressão ocular, é um tonômetro, que aplica um rápido e preciso jato de ar no centro da córnea e detecta o seu aplanamento calculando a variação dos sinais dos sensores elétrico-ópticos voltados para a córnea (LUCE apud MEDEIROS, 2011). O exame é realizado em um olho por vez.


Para detectar o aplanamento da córnea, raios ultravioletas são emitidos contra a córnea e os sensores elétrico-ópticos detectam o retorno desse raio, captando sua convergência ou divergência que representam respectivamente a maior aplanção e menor aplanção da córnea.

O ORA registra a aplanção da córnea e a pressão do ar aplicado em duas curvas que são resultantes do exame, além de 42 parâmetros calculados pelo aparelho. Para conhecer em detalhes da realização do exame e a composição dos sinais de aplanção e pressão são apresentados os seis passos a seguir (REICHERT TECHNOLOGIES, 2013):

Passo 1 – Início do exame

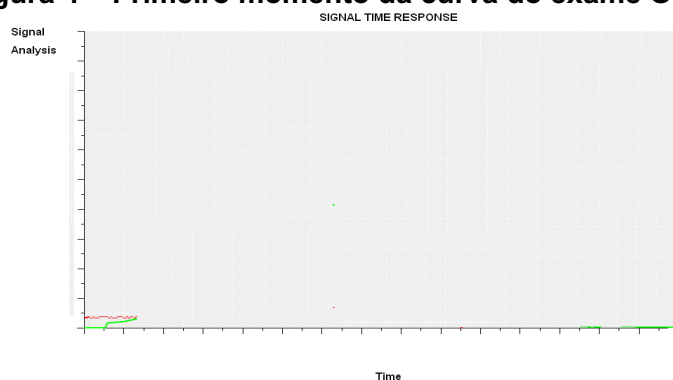
A córnea ainda está em seu estado normal e o jato de ar começa a sair do aparelho no mesmo instante que o aplanamento da córnea começa a ser monitorado pelos sensores (Figuras 3 e 4).

Figura 3 – Passo 1 do exame ORA.



Fonte: Adaptado de FONDATION OPHTALMOLOGIQUE ADOLPHE DE ROTHSCHILD,2013.

Figura 4 – Primeiro momento da curva do exame ORA.




Fonte: Adaptado de FONDATION OPHTALMOLOGIQUE ADOLPHE DE ROTHSCHILD,2013.

Passo 2 – Primeiro aplanamento

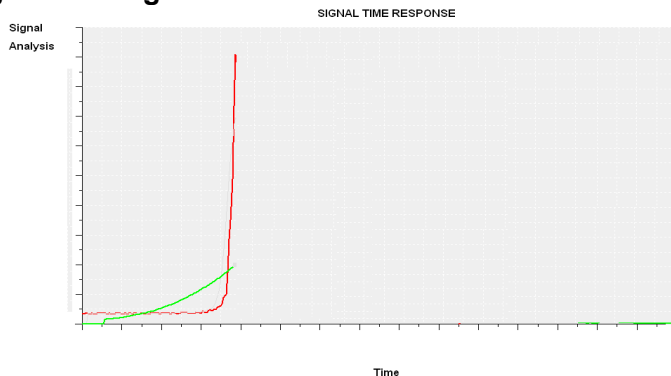
Com a pressão do jato de ar, a córnea que em seu estado normal é curva fica plana, neste instante o sinal de aplanação apresenta o seu primeiro pico (P1) e o sinal da pressão continua crescente (Figuras 5 e 6).

Figura 5 – Passo 2 do exame ORA.



Fonte: Adaptado de FONDATION OPHTALMOLOGIQUE ADOLPHE DE ROTHSCHILD,2013.

Figura 6 – Segundo momento da curva do exame ORA.




Fonte: Adaptado de FONDATION OPHTALMOLOGIQUE ADOLPHE DE ROTHSCHILD,2013.

Passo 3 – Córnea se move para dentro

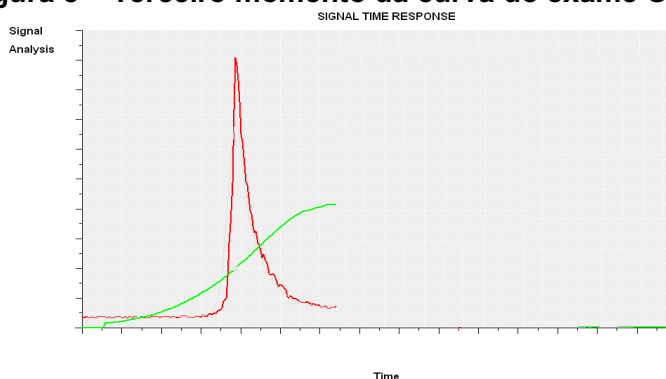
Com a crescente pressão do ar a córnea se move para dentro e deixa de ser plana, este instante o sinal de aplanção decresce com velocidade e a curva da pressão registra seus maiores valores (Figuras 7 e 8).

Figura 7 – Passo 3 do exame ORA.



Fonte: Adaptado de FONDATION OPHTALMOLOGIQUE ADOLPHE DE ROTHSCHILD,2013.

Figura 8 – Terceiro momento da curva do exame ORA.




Fonte: Adaptado de FONDATION OPHTALMOLOGIQUE ADOLPHE DE ROTHSCHILD,2013.

Passo 4 – Parado o jato de ar

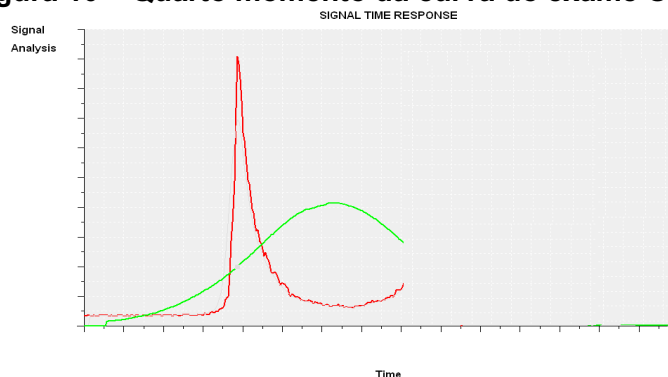
Milissegundos após a primeira aplanção o jato de ar é desligado e então o sinal da pressão registra seu decaimento e a córnea começa a sair do estágio curvada para dentro, começado a crescer o sinal de aplanação (Figuras 9 e 10).

Figura 9 – Passo 4 do exame ORA.



Fonte: Adaptado de FONDATION OPHTALMOLOGIQUE ADOLPHE DE ROTHSCHILD,2013.


Figura 10 – Quarto momento da curva do exame ORA.



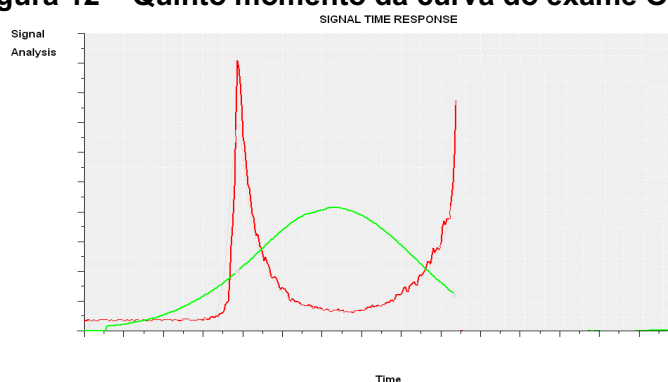
Fonte: Adaptado de FONDATION OPHTALMOLOGIQUE ADOLPHE DE ROTHSCHILD,2013.

Passo 5 – Segundo aplanamento

Com o decaimento da pressão do ar a córnea começa a voltar ao seu estado normal, mas para isso passa pelo seu segundo momento de aplanação registrando no sinal o segundo pico (P2) e o sinal da pressão continua decrescente (Figuras 11 e 12).

Figura 11 – Passo 5 do exame ORA.


Fonte: Adaptado de FONDATION OPHTALMOLOGIQUE ADOLPHE DE ROTHSCHILD,2013.

Figura 12 – Quinto momento da curva do exame ORA.

Fonte: Adaptado de FONDATION OPHTALMOLOGIQUE ADOLPHE DE ROTHSCHILD,2013.

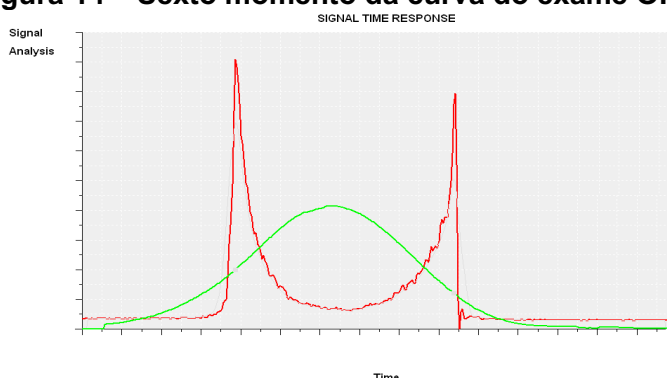
Passo 6 – Término do exame

Neste último passo a córnea já está de volta a seu estágio normal e não existe mais a presença do jato de ar, completando os 400 pontos de cada sinal e finalizando o exame (Figuras 13 e 14).

Figura 13 – Passo 6 do exame ORA.

Fonte: Adaptado de FONDATION OPHTALMOLOGIQUE ADOLPHE DE ROTHSCHILD,2013.

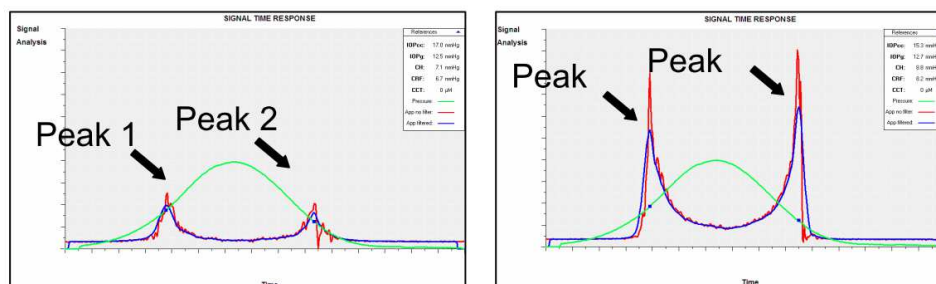
Figura 14 – Sexto momento da curva do exame ORA.



Fonte: Adaptado de FONDATION OPHTALMOLOGIQUE ADOLPHE DE ROTHSCHILD,2013.

Como padrão os dois sinais em todos os exames possuem 400 pontos que representam a curva. Como mostra a Figura 9 os picos da aplanção, no inglês *peak*, são muito significativos para distinção de córneas com ceratocone e normais (GLASS,2008), destacando que a Figura 15 apresenta casos extremos de normal e ceratocone.

Figura 15 – Picos são significativos para detecção de ceratocone.



Keratoconic cornea

Normal cornea

Fonte: GLASS,2008.

Com isso foram mostrados os principais exames para a detecção do ceratocone, bem como o aparelho usado para capturar dados biomecânicos da córnea. Seguindo com o referencial teórico, será discutido sobre Inteligência Artificial (IA).

3 INTELIGÊNCIA ARTIFICIAL BASEADA EM APRENDIZAGEM DE MÁQUINA

De acordo com REZENDE (2005) o objetivo das pesquisas em Inteligência Artificial é fazer o computador executar funções que são desempenhadas pelo ser humano usando conhecimento e raciocínio. Entende-se que ações inteligentes são provenientes do conhecimento, então a máquina precisa ser capaz de incorporar conhecimento em seus algoritmos para tomar decisões utilizando esse conhecimento e raciocínio. (REZENDE et al., 2005)

Esta ideia de sistemas baseados em conhecimento iniciou com os sistemas especialistas, que tentam reproduzir o processo de decisão de um especialista, racionalizando em cima do conhecimento armazenado. Entretanto passar o conhecimento de um especialista para a máquina é uma tarefa complexa, tal dificuldade foi intitulada como Gargalo de Feigenbaum (MELLI,2013).

Diante desta dificuldade nasceu à necessidade da criação de um algoritmo que aprendesse sozinho, assim, o conhecimento seria adquirido de forma automática. Daí surgiu à área da IA chamada Aprendizagem de Máquina. (FACELI et al., 2011)

3.1 Aprendizagem de Máquina

A Aprendizagem de Máquina (AM) é uma das áreas da computação que mais cresce nos últimos anos, vários problemas já foram resolvidos utilizando esta abordagem: detecção de fraudes em cartão de crédito, reconhecimento de fala e diagnóstico de câncer são alguns deles. (FACELI et al., 2011)

Definida por Mitchell (1997 apud FACELI et al., 2011, p. 3) como: a capacidade de melhorar o desempenho na realização de alguma tarefa por meio da experiência. Na AM os algoritmos são preparados para aprender, melhorar seu desempenho, com a experiência, para isso eles usam o princípio de indução. Tirando conclusões gerais a partir de um conjunto de dados de exemplos do problema. (FACELI et al., 2011)

3.1.1 Indução

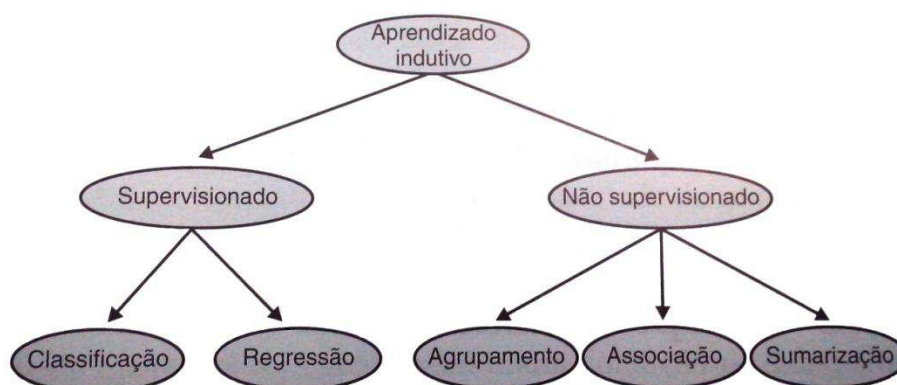
Definindo formalmente a tarefa da inferência indutiva pura (ou indução) seria: dado um conjunto de exemplos de f , retornar uma função h que se aproxime de f . A função h é chamada hipótese, uma boa hipótese é aquela que generaliza bem,

acertando a previsão dos casos ainda não conhecidos (RUSSELL; NORVIG,2004). O trabalho dos algoritmos de aprendizagem é encontrar a melhor função hipótese.

Diferentes tarefas de indução são realizadas pelos algoritmos de AM e elas podem ser agrupadas segundo o paradigma de aprendizado. De acordo com este critério é possível dividir os algoritmos em dois grupos: supervisionado e não supervisionado. Existe também o aprendizado por reforço que não será discutido neste trabalho. (RUSSELL;NORVIG,2004)

Algoritmos do tipo supervisionados, também chamados de preditivos, tem conhecimento da saída desejada e a utiliza para monitorar seus acertos ou erros. Este método se subdivide em: classificação e regressão. Já os métodos ou algoritmos não supervisionados também chamados de descritivos não possuem informação sobre uma saída desejada e precisam identificar padrões no meio de toda a base de dados, este método tem três subdivisões: agrupamento, associação e sumarização. (FACELI et al., 2011). Ver Figura 16 a seguir:

Figura 16 – Hierarquia de aprendizagem.



Fonte: FACELI et al, 2011.

O foco deste trabalho está sobre os algoritmos supervisionados, pois como será detalhado a seguir, o problema a ser trabalhado trata-se de uma classificação.

3.1.2 Modelos supervisionados ou preditivos

Devido a natureza do problema observado neste trabalho será dado ênfase nos métodos supervisionados ou preditivos que são aplicados em problemas de classificação ou regressão.

Nos casos de classificação é necessário prever uma classe do tipo nominal que representam um conceito, por exemplo: {baixo, médio, alto} ou {normal, doente}.

Em problemas de regressão é necessário prever classes do tipo numérico infinito e ordenado. (FACELI et al., 2011)

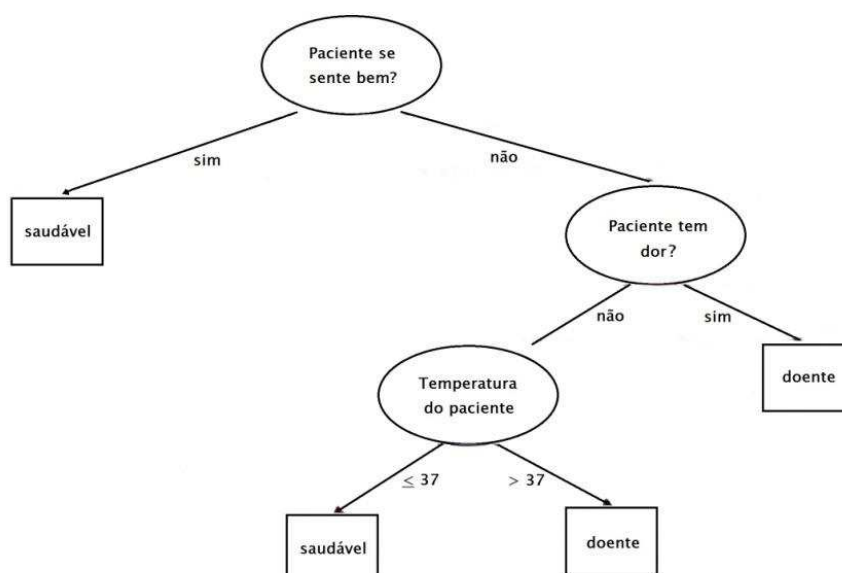
Como o modelo a ser desenvolvido neste trabalho pretende identificar a presença do ceratocone leve (graus I e II), as classes possíveis de predição serão “NORMAL”, onde não há a presença do ceratocone e “CERATOCONE” onde há a presença da patologia. Assim este trabalho trata de um problema de classificação, pois se pretende prever classes do tipo nominal.

A seguir serão apresentados os modelos preditivos que foram utilizados para classificação neste trabalho.

3.1.2.1 Árvore de decisão

As árvores de decisão são uma das formas mais simples de indução (RUSSELL;NORVIG,2004). Estas possuem: nó folha e nó decisão. O primeiro representa uma classe e o segundo um teste que utiliza como base um atributo, como mostra a Figura 17 a seguir: (REZENDE et al., 2005)

Figura 17 – Exemplo de árvore de decisão



Fonte: REZENDE,2005.

A árvore de decisão atinge sua decisão executando uma sequência de testes lógicos, a representação de árvore de decisão é considerada natural e de simples entendimento. (RUSSELL;NORVIG,2004)


Este tipo de representação foi utilizada com a intenção de melhor apresentar e discutir o modelo gerado com os especialistas do problema, neste caso os cirurgiões refrativos, entendendo assim como se alcançou o resultado. O algoritmo de aprendizagem de máquina utilizado neste trabalho para construir as árvores de decisão foi o C4.5 (QUINLAN, 1993).

3.1.2.2 Rede neural

Como definido por Braga, Carvalho & Ludemir 2000 e Haykin 1994 (apud REZENDE,2005): as Redes Neurais Artificiais (RNAs) são modelos matemáticos que se assemelham as estruturas neurais biológicas e que têm capacidade de adquirir conhecimento por meio de aprendizado e generalização.

O processo de aprendizado é gradativo e normalmente está intimamente ligado a capacidade de adaptação dos parâmetros ou pesos a medida que interage com o meio externo. Em RNAs o armazenamento e processamento da informação é feita de maneira paralela e distribuída por elementos processadores chamados de neurônios artificiais. (REZENDE et al., 2005)

Figura 18 – Neurônio artificial de McCulloch e Pitts.



Fonte: REZENDE,2005.

A Figura 18 apresenta um neurônio artificial, também conhecido como modelo de McCulloch e Pitts (1943). Nas RNAs essas unidades estão densamente interconectadas e podem estar dispostas em uma ou mais camadas interligadas por várias conexões geralmente unidirecionais. (REZENDE et al., 2005)

Uma rede com mais de uma camada recebe o nome de rede multicamadas onde a camada que resulta os valores de saída é chamada de camada de saída e as demais camadas intermediárias, escondidas ou ocultas. (FACELI et al., 2011)

A seguir serão detalhados dois tipos de rede neural, a rede perceptron de múltiplas camadas conhecida como MLP e a rede de função de base radial conhecida como RBF.

3.1.2.2.1 Rede perceptron de múltiplas camadas

A rede perceptron de múltiplas camadas, do inglês *MultiLayer Perceptron* (MLP), é um tipo de rede neural que possui uma ou mais camadas intermediárias de neurônios e uma camada de saída. Em sua arquitetura mais comum possui todos os neurônios de uma camada conectados a todos os neurônios da próxima camada. (FACELI et al., 2011)

Este tipo de rede estabelece uma função hipótese única, pois a rede MLP analisa o problema como um todo e ganha experiência em todos os casos. O algoritmo de aprendizagem de máquina utilizado neste trabalho para construir as redes neurais do tipo MLP foi o *backpropagation* implementado pela ferramenta RapidMiner® (RAPIDMINER, 2013).

O algoritmo *backpropagation* é um método de aprendizagem que pode ser dividido em duas fases: propagação e ajuste dos pesos, onde o erro é sempre levado para trás e reprocessado, essas fases são repetidas até que o desempenho da rede seja considerado bom. (RAPIDMINER, 2013)

3.1.2.2.2 Rede de função de base radial (RBF)

A Rede de função de base radial, do inglês *Radial Basis Functions Networks* (RBFN), é um tipo de rede neural artificial que implementa as regras Bayesianas. As funções de base radial são funções potenciais que são incorporadas em uma rede neural de duas camadas em que cada unidade oculta implementa uma função radial ativada capaz de receber entradas não linear e retornar saída linear. (BORS,2001)

Redes RBFs possuem grande capacidade de aproximação, devido a isso consegue modelar mapeamentos complexos. Várias aplicações das RBFs já são consideradas sucesso, exemplos: reconhecimento de fala, restauração de imagens, modelagem da série temporal caótica, estimativa de movimento e outros. (BORS,2001)

Um pouco diferente da MLP as RBF's analisam o problema de forma particionada, gerando funções diferentes para cada parte analisada. O algoritmo de aprendizagem de máquina utilizado neste trabalho para construir as redes neurais

do tipo RBF foi o algoritmo implementado pela ferramenta Weka® (THE UNIVERSITY OF WAIKATO, 2013).

Como apresentado, os três tipos de representações escolhidas possuem características distintas: as árvores de decisão utilizam testes lógicos para atingir o resultado, as redes neurais do tipo MLP utiliza função matemática única para atingir o resultado e as RBFs funções distintas dividindo o problemas para analisa-los. Por isso a escolha das três representações, para desenvolver os modelos deste trabalho.

Assim se conclui a discussão sobre a representação dos modelos preditivos. A seguir será explorado o assunto conjunto de dados, necessário para compreensão do conjunto de dados analisado e dos tratamentos realizados neste conjunto.

3.1.3 Conjunto de dados

O conjunto de dados ou base utilizada pelo método de indução é um conjunto de objetos. Este pode ser comparado a uma tabela, onde cada linha é um objeto que possui atributos ou características representados pelas colunas.

O objeto ou exemplo descrito pode ser físico (uma cadeira) ou abstrato (sintomas de um paciente), mas sempre poderá ter suas características armazenadas. Para o processo de indução sempre será necessário que o conjunto de dados esteja no formato de uma tabela (atributo-valor). (FACELI et al., 2011)

Neste problema o conjunto de dados é composto de resultados de exames realizados no aparelho ORA (*Ocular Response Analyzer*). O exame completo contém atributos como: informações do paciente (idade, sexo, etc.), parâmetros calculados pelo aparelho e as curvas de pressão e aplanção. Sendo estes últimos o foco deste trabalho.

O conjunto de dados recebido foi um arquivo em formato “.xls” do pacote Office® e possuía o total de 314 exames, de olhos normais e com ceratocone em vários estágios definidos pela classificação de Krumeich. Todos os o exames foram classificados pelo mesmo médico especialista.

Antes de utilizar a aprendizagem de máquina é recomendado fazer o pré-processamento do conjunto de dados, a próxima seção apresenta algumas técnicas que podem ser utilizadas para este fim.

3.1.3.1 Técnicas de pré-processamento

Ações como transformações de dados, eliminação manual de atributo, integração de dados e outras. Segue uma breve lista destas técnicas segundo FACELI et al., 2011:

- **Eliminação manual de atributos:** quando o conjunto de dados contém atributos que não serão avaliados ou que não contribuem para a classificação que se quer realizar;
- **Amostragem de dados:** algumas vezes se tem uma quantidade muito grande de objetos e isso pode dificultar o processamento do algoritmo, então se seleciona alguns objetos que representam bem o problema;
- **Transformações de dados:** por exemplo, a transformação de símbolos em número ou vice versa e ainda alteração de escala e outros;
- **Integração de dados:** pode ser entendido como recuperar características que não existem no conjunto atual, mas existem em outro conjunto;
- **Limpeza de dados:** quando existem dados com ruídos e é possível identificá-los é necessário remove-los para não prejudicar a execução, normalmente a identificação destes casos é feita por um especialista do problema que a base representa;
- **Balanceamento de dados:** quando uma base possui muitos casos da mesma classe a ponto de interferir e comprometer o desempenho do algoritmo é necessário balanceá-la equilibrando a quantidade de objetos de cada classe de uma forma que não comprometa o resultado.

Do conjunto recebido de 314 exames, destes 226 são casos normais e 88 possuem ceratocone de diversos graus. Foram utilizadas as técnicas de pré-processamento: limpeza de dados e a remoção de atributos.

Como o objetivo é detectar casos leves de ceratocone foram retirados os casos de ceratocone avançados. Com isso, os 20 casos de graus 3 e 4 saíram da amostra, permanecendo apenas os casos de ceratocone leve e os normais. Também foram excluídos exames considerados pelo especialista como inválidos, destes 3 possuíam ceratocone e 90 eram casos normais. Finalizando a limpeza de dados.

Aplicando a técnica de remoção de atributos, os atributos referentes aos 42 parâmetros calculados pelo aparelho foram removidos assim como os demais dados como idade, sexo permanecendo apenas o foco deste experimento que são as curvas de pressão e aplanção.

Após o pré-processamento a amostra ficou com 65 casos de ceratocone leves e 136 casos normais.

Agora que se conhece o conjunto de dados a ser trabalhado será apresentado como funciona a aprendizagem automática dos modelos de classificação.

3.1.4 Aprendizagem automática de classificadores

Como já mencionado anteriormente, o objetivo dos algoritmos de aprendizagem de máquina é aprender com a experiência. Mas como realmente acontece esse aprendizado? Todo o processo acontece em duas etapas: treinamento e teste.

O treino é o momento onde o algoritmo constrói o modelo a partir dos exemplos separados para esta etapa. A fase de teste serve para a validação do modelo construído, avaliando as previsões realizadas com o conjunto de exemplos destinados para teste, diferentes do conjunto de treino.

O processo acontece nessas duas etapas para garantir que o modelo criado tenha uma boa capacidade de generalização, para continuar a ser válido para novos objetos.

A interação treinamento e teste pode ser realizada de várias maneiras, o método mais utilizado é a validação cruzada do inglês *cross-validation*. (FACELI et al., 2011)

3.1.4.1 Validação cruzada

No método de validação cruzada, o conjunto total de objetos é dividido em r conjuntos de tamanhos aproximadamente iguais, destes r conjuntos um é separado para teste e nos demais acontece o treinamento, este processo é realizado r vezes, testando uma vez com cada conjunto. (FACELI et al., 2011)

Variações deste processo são: (1) dividir de forma estratificada, onde se mantém a mesma proporcionalidade das classes nos subconjuntos e (2) *leave-one-out* onde cada objeto é retirado uma vez para teste enquanto os demais são utilizados para treino. (FACELI et al., 2011)

Ao final da execução dos testes de previsão são calculados percentuais de avaliação, uma forma fácil e comumente utilizada para visualização destes resultados é a matriz de confusão.

3.1.4.2 Matriz de confusão

A matriz de confusão apresenta o número de predições corretas e incorretas de cada classe, para isso as colunas da matriz representam as classes verdadeiras e as linhas as classes preditas pelos algoritmos de classificação. Uma matriz de confusão M_c de k classes terá dimensão de $k \times k$, k linhas e k colunas, e cada elemento desta matriz m_{ij} representa a quantidade de objetos classificados na classe i que são da classe j . Quando a classe i e j são iguais temos situações de acertos, estas quantidades ficam na diagonal da matriz, os demais elementos são erros. (FACELI et al., 2011)

Considerando um problema de duas classes, normalmente identificadas como classe positiva e classe negativa, sua matriz de confusão pode ser representada como mostrado na Figura 19 segundo FACELI et al. (2011):

Figura 19 – Matriz de confusão para duas classes.

		Classe Verdadeira	
		+	-
Classe Predita	+	VP	FP
	-	FN	VN

Fonte: FACELI et al., 2011.

Onde:

VP – Verdadeiro Positivo: objetos preditos como positivos e o classificador acertou;

VN – Verdadeiro Negativo: objetos preditos como negativos e o classificador acertou;

FP – Falso Positivo: objetos preditos como positivos e o classificador errou;

FN – Falso Negativo: objetos preditos como negativos e o classificador errou.

A partir da matriz de confusão vários cálculos podem ser feitos para localizar medidas de desempenho, na Tabela 2 a seguir apresenta alguns deles:

Tabela 2 – Medidas de desempenho da matriz de confusão.

MEDIDAS DE DESEMPENHO	FÓRMULA
Taxa de acerto ou acurácia total	$\frac{VP + VN}{n}$

Precisão	$\frac{VP}{VP + FP}$
Sensibilidade	$\frac{VP}{VP + FN}$
Especificidade	$\frac{VN}{VN + FP}$
Taxa de erro da classe positiva	$\frac{FN}{VP + FN}$
Taxa de erro da classe negativa	$\frac{FP}{VN + FP}$
Taxa total de Erro	$\frac{FP + FN}{n}$

Fonte: Adaptado de FACELI et al., 2011.

Aqui termina a sessão referente a aprendizagem de máquina. Como já indicado o modelo computacional desenvolvido também utilizará processamento de sinais, na próxima sessão este assunto será explorado.

4 PROCESSAMENTO DE SINAIS

Como definido por Marcelo P. de Albuquerque (apud LABORATÓRIO DE PROCESSAMENTO DIGITAL DE SINAIS E IMAGENS,2013) sinal é uma função de variáveis independentes e está muito presente em nosso cotidiano. Música, voz e imagens são exemplos de sinais.

Estes sinais representam e possuem informações, informações importantes e não importantes, os chamados ruídos. Processamento ou tratamento de sinais tem como objetivo extrair a informação importante e se baseiam em vários ramos da física e matemática para isso, utilizando o processo de filtro que separa um sinal de seu ruído.

Como já se sabe este trabalho pretende analisar a biomecânica da córnea a partir da aplanção e pressão aplicada calculados a partir do aparelho ORA. Ambos são sinais e com a intenção de extrair a sua essência e remover os ruídos foi decidido utilizar uma técnica de processamento de sinais.

Entre as técnicas de processamento de sinais mais utilizadas destacam-se dois nomes: Fourier e Wavelet (FARIAS,1997), entre estas duas técnicas de processamento optou-se por Wavelet porque esta possui a precedente temporal relevante no problema deste trabalho, diferente da técnica de Fourier que só trabalha a frequência e amplitude do sinal. A seguir a técnica de processamento wavelet é detalhada.

4.1 Wavelet

Wavelets são funções capazes de processar sinais. Uma técnica de processamento de sinais que surgiu algumas décadas após os estudos de Fourier. O termo "wavelet" esteve presente inicialmente na literatura francesa na área de geofísica na década de 1980 (STRANG,1996 apud FARIAS,1997). Comparando Fourier e Wavelets é possível verificar semelhanças e diferenças importantes que esclarecem certas vantagens no uso das wavelets para o problema ou sinal em questão. (FARIAS,1997)

Na Teoria de Fourier um sinal pode ser representado como uma série de senos e cossenos onde todas as componentes de frequência do sinal podem ser determinadas, mas como desvantagem a identidade temporal do sinal é perdida. Wavelets são capazes de representar o sinal concomitantemente no domínio do tempo e da frequência. (VALENS, 1999 apud ARAUJO,2011)

Ainda hoje investigações sobre wavelets estão ativas, principalmente nos Estados Unidos, onde são lideradas por trabalhos de pesquisadores como Ingrid Daubechies, Ronald Coifman, Vitor Wickerhauser, Yves Mayer, Alex Grossmann e George Zweig. (ANDRADE,2009)

4.2 Transformada Wavelet

Wavelets são “ondas pequenas” que associam funções obtidas a partir de uma função protótipo, denominada wavelet mãe, por meio de escalamento e translações. O principal objetivo ao se realizar estas operações é obter uma família de base para descrever outras funções. (ANDRADE,2009)

Uma família de wavelets surge por meio do escalamento e translações da wavelet mãe apresentada na fórmula (1) a seguir:

$$\Psi_{a,b}(t) = |a|^{-1/2} \Psi\left(\frac{t-b}{a}\right) \quad a, b \in \mathbb{R}, a \neq 0 \quad (1)$$

Existem as transformada wavelet contínua e a transformada wavelet discreta. A transformada wavelet contínua (ou integral) com respeito à família de wavelets da equação anterior é apresentada na fórmula (2) a seguir:

$$F(a, b) = |a|^{-1/2} \int_{-\infty}^{+\infty} f(t) \cdot \bar{\Psi}\left(\frac{t-b}{a}\right) dt = \langle f(t), \bar{\Psi}_{a,b}(t) \rangle \quad (2)$$

Onde $F(a,b)$ são os coeficientes: a (escala) e b (deslocamento), variáveis do sinal transformado. $\bar{\Psi}$ é o complexo conjugado de Ψ . A função $f(t)$ pode ser recuperada de $F(a,b)$ através da resolução de identidade de Calderón. (FARIAS,1997)

Esta transformada wavelet contínua é mais utilizada na matemática, pois por ser contínua, entenda-se infinita, a computação utiliza sua forma discreta que veremos a seguir.

A transformada wavelet discreta (TWD) pode ser expressa como mostra a fórmula (3) a seguir:

$$d_{j,k} = \langle \Psi_{j,k}(t), f(t) \rangle = \int f(t) \Psi_{j,k}(t) dt \quad (3)$$

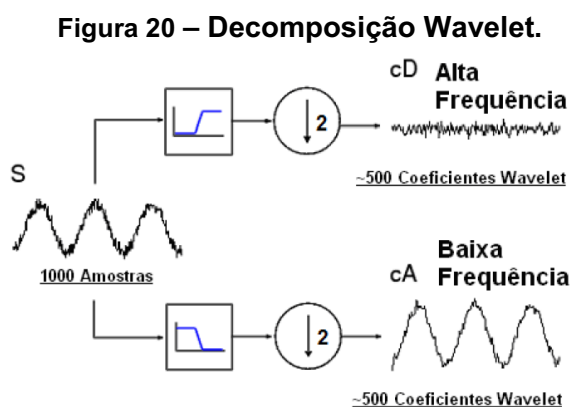
Onde $d_{j,k}$ são os coeficientes wavelets, correspondentes a $F(a,b)$ da transformada integral.

Como este trabalho é necessário processamento computacional será utilizada a transformada de wavelet discreta a partir da decomposição wavelet melhor detalhada a seguir.

4.3 Decomposição Wavelet

SOUZA (2007) afirma que uma wavelet é uma função que ao obedecer a certos requisitos matemáticos pode ser utilizada para decompor ou descrever (ARAUJO,2011). A decomposição realizada pela Transformada Wavelet Discreta (TWD) utiliza os conceitos de coeficiente de aproximação (cA) e coeficientes de detalhe (cD), onde os detalhes são de pequena escala e relacionadas com componentes de alta frequência, já as aproximações são de grande escala e relacionadas com componentes de baixa frequência. (ANDRADE,2009)

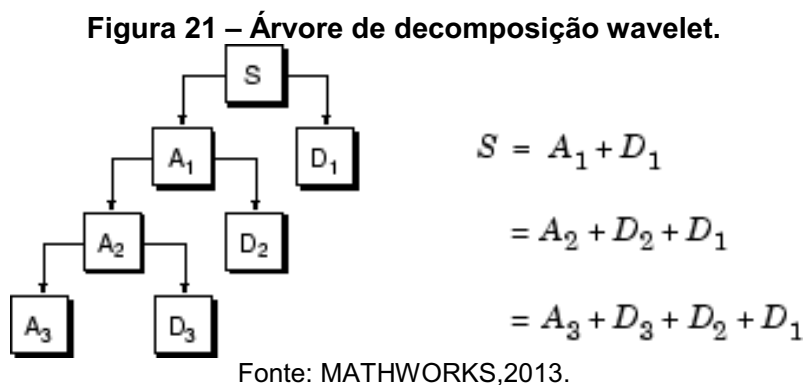
O algoritmo de decomposição extrai metade dos pontos do sinal de entrada, processo chamado de subfiltragem que resulta os coeficientes de aproximação e coeficientes de detalhes cada um com metade das amostras do sinal como mostra a Figura 20. (ANDRADE,2009)



Fonte: ANDRADE,2009.

O processo de decomposição pode ser realizado em quantidades diversas de níveis, cada nível resulta aproximações e/ou detalhes sendo sucessivamente decompostos, e o sinal dividido em componentes de menor resolução resultando em

uma árvore de decomposição wavelet (Figura 21). O processo de decomposição pode seguir até existir apenas uma mostra. (MATHWORKS,2013)



4.4 Compressão de Sinais

Compressão de sinais utilizando Transformada Wavelet Discreta (TWD) se resume a desconsiderar os coeficientes de detalhes (altas frequências) e manter apenas os coeficientes de aproximação (baixas frequências). O fundamento deste método é que a informação do sinal se concentra principalmente nos componentes de baixa frequência que compõem a identidade do sinal e a parte significativa da informação, já os componentes de alta frequência são considerados ruídos e normalmente possuem apenas informações irrelevantes, as nuances e modulações. Assim o uso da TWD na compressão de sinais acontece sem comprometer a essência da informação que estes carregam. (ANDRADE,2009)

O processo de decomposição da aproximação pode ser diversas vezes repetido e o coeficiente de detalhe descartado, quanto houver informação suficiente para a aplicação desejada do sinal comprimido. Uma das aplicações mais conhecidas das wavelets é na computação gráfica para compressão de imagens, análise de textura, enfoque, magnificação, interpolação e vários outros.

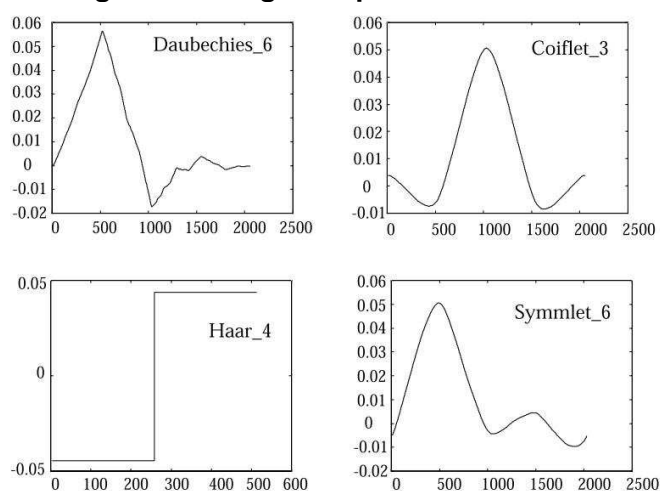
4.5 Tipos de Wavelets

Vários tipos de wavelets (Figura 22) são citados na literatura, a escolha do tipo depende da aplicação, segue os tipos mais utilizados (FARIAS,1997; ANDRADE,2009; ARAUJO,2011):

- **Coiflets (Coif):** tem como base a definição da quantidade de momentos nulos. Família de wavelets que possui 5 tipos: Coiflets 1, Coiflets 2, Coiflets 3, Coiflets 4 e Coiflets 5.

- **Daubechies (Db):** wavelet que possui momentos nulos, isso é útil na compressão, mas é considerada assimétrica, então pode provocar pequenas distorções em processamento de som. Daubechies é uma família que possuem 10 tipos de wavelets, Daubechies de 1 a 10.
- **Haar:** a primeira wavelet criada e mais simples, lembra uma função degrau, pode ser considerada uma Daubechies 2;
- **Simétricas ou Simlets (symmlets):** são as wavelets "menos assimétricas", de suporte compacto e número de momentos nulos é variável;

Figura 22 – Alguns tipos de wavelets.



Fonte: BIOCYBERNETICS,2013.

Entre os tipos de decomposição wavelets descritos acima foram utilizadas neste trabalho Coiflets1 (Coif1), Coiflets5 (Coif5), Daubechies5 (Db5), Daubechies10 (Db10) e Haar, na intenção de processar os sinais nos mais diferentes tipos de wavelets e estas de adéquam ao sinal a ser explorado.

Coiflets1 e Coiflets5 são os dois extremos do tipo wavelet Coiflets, como a wavelet Haar é semelhante a Daubechies2, foi utilizado Daubechies5 e Daubechies10 como meio e extremo do tipo wavelet Daubechies.

Visto o conteúdo necessário para o entendimento do modelo computacional que se pretende desenvolver é possível iniciar a explicação da criação deste modelo, a sessão seguinte tem está pretensão.

5 CONSTRUÇÃO DO MODELO COMPUTACIONAL

O objetivo deste trabalho é construir um modelo computacional para auxiliar o cirurgião refrativo na detecção de ceratocone. Atualmente, os exames mais comuns utilizados para a detecção de ceratocone são exames baseados em imagens como: topografia e tomografia. Recentemente, estão surgindo novos exames capazes de analisar a biomecânica da córnea, a córnea em movimento.

A biomecânica da córnea é uma área relativamente nova na oftalmologia que ainda não foi suficientemente explorada. Entretanto esta possui grande propensão para contribuir na detecção de ceratocone, pois como foi mencionado no capítulo 2 deste trabalho e citado por Dianne H. Glass: o ceratocone modifica a biomecânica da córnea.

A grande questão é: como prever a predisposição ao ceratocone utilizando a biomecânica da córnea? Sabe-se que utilizando a área da IA chamada Aprendizagem de Máquina (AM) é possível, com um conjunto de amostras, treinar um algoritmo para prever um resultado em casos não treinados.

Como a intenção deste trabalho é justamente identificar a presença do ceratocone, classificando entre as classes “NORMAL” ou “CERATOCONE”. E não se sabe como programar algoritmicamente tal classificador, a aprendizagem de máquina é uma escola natural para o problema. Pois esta tem a capacidade de extrair um modelo, ou adquirir tal conhecimento a partir dos exemplos de olhos normais e com ceratocone.

Uma outra questão que precisa ser respondida é: qual seria a amostra necessária para a criação do modelo? Como o único aparelho presente no mercado, até o início deste trabalho, capaz de analisar a biomecânica da córnea era o ORA então seria necessário obter amostra de resultados deste exame.

Para obter esse conjunto de amostras foi utilizada a parceria já existente do Instituto de Olhos Renato Ambrósio do Rio de Janeiro - Brasil com o grupo BrAIIn – Brazilian Study Group of Artificial Intelligence and Corneal Analysis que desenvolveu o atual experimento.

Então o conjunto de dados recebidos foi uma amostra de 314 exames realizados em uma instituição privada, o Instituto de Olhos Renato Ambrósio, no período de 2007 a 2009 que contêm casos normais e casos com ceratocone.

Os exames da amostra possuíam várias informações, entre elas os parâmetros já calculados pelo ORA e os dois sinais de aplanção e pressão, dos quais este experimento analisou apenas os sinais. Os parâmetros calculados pelo aparelho foram analisados em outro trabalho também realizado pelo grupo de pesquisa BrAln (VENTURA,2013).

Com o conjunto de dados em mãos era necessário definir que modelos e algoritmos seriam utilizados para aprendizagem. Como já comentado pretende-se classificar entre as classes “NORMAL” ou “CERATOCONE”, para isso as representações de classificação são mais adequados, pois são capazes de predizer classes nominais.

Entre os possíveis modelos preditivos capazes de faz classificações utilizou-se a redes neurais dos tipos MLP e RBF e também árvore de decisão. O propósito da avaliação destes diferentes tipos de classificadores é que eles possuem diferentes características para representar e adquirir o conhecimento, como foi apresentado no capítulo 3.

Como já visto no capítulo 3, árvores de decisão representam o conhecimento utilizando lógica, as redes neurais do tipo MLP utilizam funções matemáticas não lineares abrangentes e a rede neural do tipo RBF, funções matemáticas não lineares estratificadas.

Para a criação do modelo, além dos algoritmos de AM foi identificada a possibilidade do uso de técnicas de processamento de sinais com a intenção de extrair a essência de sua informação, pois como já comentado, o conjunto a ser analisado são dados que representam os sinais de aplanção e pressão.

Para o processamento dos sinais foram pesquisadas as técnicas mais comumente utilizadas: Fourier e Wavelets. Como a Transformada de Fourier leva o sinal de “amplitude X tempo” para o quadrante “amplitude X frequência” desconsiderando a variável tempo importante neste problema, optou-se pela utilização da Transformada de Wavelet que leva da “amplitude X tempo” para a “frequência X tempo”.

Existe a transformada de Wavelet contínua e discreta, onde só a discreta é mais utilizada pela computação que necessita de delimitações para realizar os cálculos numéricos. A decomposição wavelet, forma de processamento de sinais, utiliza a Transformada Discreta de Wavelet e é muito utilizada para compressão de imagens e sons.

Neste problema, utilizou-se a decomposição wavelet capaz de gerar a cada decomposição um novo sinal que possui a metade de pontos do original extraído a essência da informação. Esse método foi escolhido, pois assim seria possível analisar até onde a decomposição seria positiva para o problema.

Em seguida, foi definido que o experimento teria duas fases. A primeira onde a amostra de dados seria estudada por inteiro e processada apenas pelos algoritmos de classificação na intenção de conhecer os sinais. E uma segunda fase onde os sinais, depois de conhecidos, seriam processados pela decomposição wavelet. Estas fases nomeadas como:

- Estudo geral dos sinais de pressão e aplanção (fase 1)
- Processamento Wavelet (fase 2)

Assim em cada uma dessas fases foram criados vários modelos computacionais. Na primeira fase sem a presença do processamento de sinais e na segunda fase modelos que utilizam processamento de sinais, elegendo em cada fase os modelos computacionais que responderem melhor a classificação. A seguir cada uma dessas fases será detalhada.

5.1 Estudo Geral dos Sinais de Pressão e Aplanção (Fase 1)

Nesta primeira fase, o sinal será analisado em partes separadas ou por completo. Cada parte de sinal separada para análise será constituída de um conjunto de pontos pré-definidos.

Serão estabelecidos vários conjuntos com o objetivo de analisar os sinais de formas diferentes e descobrir que partes destes sinais são mais relevantes. Ao final do experimento essa primeira fase possuía 25 conjuntos de pontos que serão detalhados a seguir.

Para o início das definições dos conjuntos foi analisado cada sinal individualmente, primeiro só os pontos da pressão depois só os pontos da aplanção.

Quatro conjuntos foram criados para análise individual da curva da pressão, o “Conjunto 1 - Todos os pontos da Pressão” agrupa todos os pontos da curva da pressão.

Como já visto, o sinal de pressão resultante do exame ORA possui como padrão apenas um ponto mais elevando, um pico, O “Conjunto 2 - Os 10 pontos antes e depois do pico da pressão” agrupa os 10 pontos antes desse pico, o ponto

que representa o pico e os 10 pontos depois do pico nos sinais da pressão da amostra de exames analisados.

O “Conjunto 3 - Os 25 pontos antes e depois do pico da pressão” e o “Conjunto 4 - Os 50 pontos antes e depois do pico da pressão” segue o mesmo raciocínio do Conjunto 2 agrupando respectivamente os 25 e os 50 pontos antes e depois do pico da pressão. Estes quatro primeiro conjuntos podem ser vistos no Quadro 1 a seguir:

Quadro 1 – Conjuntos referente ao sinal de pressão.

Nº	Conjunto	Descrição
1	Todos os pontos da Pressão	Todos os 400 pontos da pressão.
2	Os 10 pontos antes e depois do pico da pressão	Os 10 pontos antes e os 10 pontos depois do único pico da pressão e o valor do pico de cada paciente. Total de 21 pontos.
3	Os 25 pontos antes e depois do pico da pressão	Os 25 pontos antes e os 25 pontos depois do único pico da pressão e o valor do pico de cada paciente. Total de 51 pontos.
4	Os 50 pontos antes e depois do pico da pressão	Os 50 pontos antes e os 50 pontos depois do único pico da pressão e o valor do pico de cada paciente. Total de 101 pontos.

Fonte: Autora,2013.

Esses foram os quatro primeiros conjuntos que foram treinados e testados com cada um dos três algoritmos. A análise prosseguiu com o sinal de aplanção.

Foram criados 5 conjuntos iniciais para conhecer o sinal de aplanção. Diferente do sinal de pressão a aplanção possui como padrão dois picos, na mesma ideia de análise da pressão foram criados os 4 primeiros conjuntos, onde o “Conjunto 5 - Todos os pontos da Aplanção” analisa todos os pontos da aplanção juntos, semelhante ao Conjunto 1 que reuni todos os pontos do sinal da pressão.

Já os conjuntos: “Conjunto 6 - Os 10 pontos antes e os 10 depois de cada um dos dois picos da Aplanção”, “Conjunto 7 - Os 25 pontos antes e os 25 depois de cada um dos dois picos da Aplanção” e “Conjunto 8 - Os 50 pontos antes e os 50 depois de cada um dos dois picos da Aplanção” reuni os pontos ao lado dos dois picos da aplanção, respectivamente 10 pontos antes e 10 depois dos dois picos da aplanção, depois os 25 pontos, depois 50 como mostra o Quadro 2 a seguir.

Quadro 2 - Conjuntos referente ao sinal da aplanção.

Nº	Conjunto	Descrição
5	Todos os pontos da Aplanção	Todos os 400 pontos da aplanção.
6	Os 10 pontos antes e os 10 depois de cada um dos dois picos da Aplanção	Os 10 pontos antes e os 10 pontos depois de cada um dos dois picos da Aplanção e os valores de cada pico de cada paciente. Total de 42 pontos.
7	Os 25 pontos antes e os 25 depois de cada um dos dois picos da Aplanção	Os 25 pontos antes e os 25 pontos depois de cada um dos dois picos da Aplanção e os valores de cada pico de cada paciente. Total de 102 pontos.
8	Os 50 pontos antes e os 50 depois de cada um dos dois picos da Aplanção	Os 50 pontos antes e os 50 pontos depois de cada um dos dois picos da Aplanção e os valores de cada pico de cada paciente. Total de 202 pontos.

Fonte: Autora,2013.

O Quadro 3 mostra o “Conjunto 9 – Pares de pontos alternados dos picos da aplanção” também relacionado a aplanção, agora removendo metade dos pontos utilizando a seguinte lógica: deixando os dois primeiros pontos, removendo os dois próximos pontos do conjunto, deixando dois, removendo dois, com a intenção de fazer um processamento de sinal manual, reduzindo o sinal para teste dos algoritmos.

Quadro 3 – Conjuntos referente a aplanção como pontos .

Nº	Conjunto	Descrição
9	Pares de pontos alternados dos picos da aplanção	Valor dos pares de pontos alternados da aplanção: valores das posições 1,2,5,6,9,10 e assim por diante. Total de 200 pontos.

Fonte: Autora,2013.

Para analisar os picos da aplanção individualmente foram criados mais seis conjuntos, três deles referente ao primeiro pico e três referentes ao segundo pico. A intenção é descobrir se um pico sozinho tem relevância e se algum deles é mais relevante que outro para o problema.

Os três conjuntos criados referente ao primeiro pico seguem a lógica já apresentada anteriormente selecionando os 10 pontos antes e 10 depois agora

referente apenas ao pico 1, depois 25 pontos e depois 50 pontos antes e depois do pico 1.

O Quadro 4 apresenta estes três conjuntos que receberam os nomes: “Conjunto 10 - Os 10 pontos antes e os 10 depois do Pico 1 da Aplanção”, “Conjunto 11 - Os 25 pontos antes e os 25 depois do Pico 1 da Aplanção” e “Conjunto 12 - Os 50 pontos antes e os 50 depois do Pico 1 da Aplanção”.

Quadro 4 – Conjuntos referente ao Pico 1 do sinal da aplanção.

Nº	Conjunto	Descrição
10	Os 10 pontos antes e os 10 depois do Pico 1 da Aplanção	Os 10 pontos antes e os 10 depois do primeiro pico da Aplanção e o valor do pico de cada paciente. Total de 21 pontos.
11	Os 25 pontos antes e os 25 depois do Pico 1 da Aplanção	Os 25 pontos antes e os 25 depois do primeiro pico da Aplanção e o valor do pico de cada paciente. Total de 51 pontos.
12	Os 50 pontos antes e os 50 depois do Pico 1 da Aplanção	Os 50 pontos antes e os 50 depois do primeiro pico da Aplanção e o valor do pico de cada paciente. Total de 101 pontos.

Fonte: Autora,2013.

Seguindo a mesma lógica, os conjuntos referentes ao segundo pico foram criados, o “Conjunto 13 - Os 10 pontos antes e os 10 depois do Pico 2 da Aplanção” que reuni os 10 pontos antes e os 10 pontos depois do pico 2 da aplanção e os dois outros conjunto seguindo a sequencia 25 e 50 pontos antes e depois do segundo pico.

O Quadro 5 apresenta o Conjunto 13 citado acima e os conjuntos: “Conjunto 14 - Os 25 pontos antes e os 25 depois do Pico 2 da Aplanção” e “Conjunto 15 - Os 50 pontos antes e os 50 depois do Pico 2 da Aplanção”.

Quadro 5 – Conjuntos referente ao Pico 2 do sinal da aplanção.

Nº	Conjunto	Descrição
13	Os 10 pontos antes e os 10 depois do Pico 2 da Aplanção	Os 10 pontos antes e os 10 depois do segundo pico da Aplanção e o valor do pico de cada paciente. Total de 21 pontos.
14	Os 25 pontos antes e os 25 depois do Pico 2 da Aplanção	Os 25 pontos antes e os 25 depois do segundo pico da Aplanção e o valor do pico de cada paciente. Total de 51 pontos.

15	Os 50 pontos antes e os 50 depois do Pico 2 da Aplanção	Os 50 pontos antes e os 50 depois do segundo pico da Aplanção e o valor do pico de cada paciente. Total de 101 pontos.
----	---------------------------------------------------------	------------------------------------------------------------------------------------------------------------------------

Fonte: Autora,2013.

Os próximos conjuntos criados reúnem pontos dos dois sinais de pressão e aplanção para observar se os dois juntos ou parte de ambos juntos retornam bons resultados para o problema.

O primeiro conjunto definido reunia exatamente todos os pontos dos dois sinais totalizando 800 pontos e recebeu o nome: “Conjunto 16 - Todos os pontos Aplanção e Todos Pressão”, esse conjunto apresentou dificuldades em seu processamento devido ao grande número de atributos, sendo somente gerado os modelos pela rede neural tipo RBF e árvore de decisão.

O “Conjunto 17 - Os 50 pontos antes e os 50 depois dos dois picos da Aplanção junto com os valores da pressão das mesmas posições” foi criado para observar a área dos dois picos da aplanção junto à pressão, neste caso os 50 pontos antes e depois de cada pico adicionando os valores da pressão das mesmas posições.

Como ambos os sinais acontecem no mesmo tempo, no mesmo instante de tempo há um valor para a pressão e um valor para a aplanção. Utilizando as posições dos 50 pontos antes e 50 pontos depois de cada pico da aplanção foram pegos os valores da pressão destes mesmo momentos.

Seguindo esta ideia o “Conjunto 18 - Os 50 pontos antes e os 50 depois dos dois picos da Aplanção junto com o valor da primeira posição da pressão + o valor da pressão na posição do pico da aplanção + o valor da pressão na última posição da aplanção” reúne os 50 pontos antes e depois dos picos da aplanção mais os valores da pressão da primeira posição que inicia os 50 pontos antes dos picos, o valor da pressão no ponto central dos picos e o valor da pressão na última posição dos 50 pontos após os picos.

O Quadro 6 a seguir mostra estes três conjuntos: 16, 17 e 18 citados acima:

Quadro 6 – Conjuntos referente aos dois sinais: pressão e aplanção.		
Nº	Conjunto	Descrição
16	Todos os pontos Aplanção e Todos Pressão	Todos os pontos da pressão como aplanção juntos. Total de 800 pontos.

17	Os 50 pontos antes e os 50 depois dos dois picos da Aplanção junto com os valores da pressão das mesmas posições	Os 50 pontos antes e os 50 depois dos dois picos da aplanção e o valor do pico mais os valores da pressão das mesmas posições dos valores da aplanção de cada paciente. Total de 404 pontos = 202 pontos da aplanção + 202 pontos da pressão.
18	Os 50 pontos antes e os 50 depois dos dois picos da Aplanção junto com o valor da primeira posição da pressão + o valor da pressão na posição do pico da aplanção + o valor da pressão na última posição da aplanção	Os 50 pontos antes e os 50 depois dos dois picos da aplanção e o valor do pico mais os valores da pressão da primeira posição da aplanção da posição do pico e da última posição para cada paciente. Total de 208 pontos = 202 pontos da aplanção + 6 pontos da pressão.

Fonte: Autora,2013.

Seguindo a mesma ideia dos conjuntos 17 e 18, mas agora referente aos picos da aplanção individualmente foram criados quatro conjuntos para observar novamente a relevância dos picos da aplanção agora combinando com o sinal de pressão, dois deles referente ao pico 1 e dois referente ao pico 2.

O “Conjunto 19 - Os 50 pontos antes e os 50 depois do Pico 1 da Aplanção junto com os valores da pressão das mesmas posições” reúne os 50 pontos antes e depois apenas do pico 1 da aplanção mais os valores da pressão destas mesmas posições.

O “Conjunto 20 - Os 50 pontos antes e os 50 depois do Pico 1 da Aplanção junto com o valor da primeira posição da pressão + o valor da pressão na posição do pico da aplanção + o valor da pressão na última posição da aplanção” reúne os 50 pontos antes e depois do pico 1 da aplanção mais alguns valores da pressão das posições inicial, central e final deste pico.

O Quadro 7 a seguir mostra estes dois conjunto criados para observar a relevância do pico 1 combinado com valores da pressão:

Quadro 7 – Conjuntos referente aos dois sinais focando o pico 1 da aplanção.

Nº	Conjunto	Descrição
19	Os 50 pontos antes e os 50 depois do Pico 1 da Aplanção junto com os valores da pressão das mesmas posições	Os 50 pontos antes e os 50 depois do primeiro pico da aplanção e o valor do pico mais os valores da pressão das mesmas posições dos valores da aplanção de cada paciente. Total de

		202 pontos = 101 pontos da aplanção + 101 pontos da pressão.
20	Os 50 pontos antes e os 50 depois do Pico 1 da Aplanção junto com o valor da primeira posição da pressão + o valor da pressão na posição do pico da aplanção + o valor da pressão na última posição da aplanção	Os 50 pontos antes e os 50 depois do primeiro pico da aplanção e o valor do pico mais os valores da pressão da primeira posição da aplanção, da posição do pico e da última posição para cada paciente. Total de 104 pontos = 101 pontos da aplanção + 3 pontos da pressão.

Fonte: Autora,2013.

O “Conjunto 21 - Os 50 pontos antes e os 50 depois do Pico 2 da Aplanção junto com os valores da pressão das mesmas posições” reúne os 50 pontos antes e 50 pontos depois do pico 2 da aplanção mais os valores da pressão das mesmas posições.

O “Conjunto 22 - Os 50 pontos antes e os 50 depois do Pico 2 da Aplanção junto com o valor da primeira posição da pressão + o valor da pressão na posição do pico da aplanção + o valor da pressão na última posição da aplanção” junta os 50 pontos antes de pois do pico 2 da aplanção mais os valores de inicio, centro e fim da pressão em relação o pico 2 da aplanção.

O Quadro 8 a seguir apresenta estes dois conjuntos: 21 e 22:

Quadro 8 – Conjuntos referente aos dois sinais focando o pico 2 da aplanção.

Nº	Conjunto	Descrição
21	Os 50 pontos antes e os 50 depois do Pico 2 da Aplanção junto com os valores da pressão das mesmas posições	Os 50 pontos antes e os 50 depois do segundo pico da aplanção e o valor do pico mais os valores da pressão das mesmas posições dos valores da aplanção de cada paciente. Total de 202 pontos = 101 pontos da aplanção + 101 pontos da pressão.
22	Os 50 pontos antes e os 50 depois do Pico 2 da Aplanção junto com o valor da primeira posição da pressão + o valor da pressão na posição do pico da aplanção + o valor da pressão na última posição da aplanção	Os 50 pontos antes e os 50 depois do segundo pico da aplanção e o valor do pico mais os valores da pressão da primeira posição da aplanção, da posição do pico e da última posição para cada paciente. Total de 104 pontos = 101 pontos da aplanção + 3 pontos da pressão.

Fonte: Autora,2013.

Mais três conjuntos bem diferentes foram criados unindo os sinais de pressão e aplanação. Pensou-se na possibilidade da informação do tempo, observando se a posição pode ser relevante, então os conjuntos 23 e 24, melhor detalhados a seguir, contêm dados referente à posição.

O “Conjunto 23 - Os 50 pontos antes e os 50 depois dos Picos da Aplanação junto com o + posição do pico da pressão + posição do pico 1 + posição do pico 2 + valor do pico da pressão” armazena os 50 pontos antes e depois dos dois picos da aplanação mais o valor do tempo onde acontece os picos: da pressão, o pico 1 e 2 da aplanação e também o valor do pico da pressão.

O “Conjunto 24 - O valor das posições relativas ao pico: -50, -25, o pico, 25 e 50 antes e depois dos Picos da Aplanação junto com a posição do pico da pressão + posição do pico 1 + posição do pico 2 + valor do pico da pressão” contêm o valor da aplanação das posições 50 pontos antes dos picos, 25 pontos antes dos picos, os valores dos dois picos, 25 posições após os picos e o valor de 50 posições após cada pico, mais a posição que acontece os dois picos da aplanação e o pico da pressão e o valor do pico da pressão. Estas posições colocam no conjunto 24 a informação de onde aconteceram as aplanações, para que seja verificado se essa informação é importante.

O último conjunto criado para teste envolve a operação matemática de convolução entre os dois sinais, a convolução é o cálculo da área da união de dois sinais. Assim foi feito entre os dois sinais abrangendo apenas os 50 pontos antes e depois dos dois picos da aplanação.

Este conjunto recebeu o nome: “Conjunto 25 - Convolução dos 50 pontos antes e depois dos picos da aplanação com os pontos da pressão dos mesmos momentos”. Uma observação em relação ao conjunto 25 é que não foi criado o modelo baseado na árvore de decisão, pois já que o sinal havia sido modificado, não seria então necessário verificar os momentos mais relevantes da curva.

A seguir o Quadro 9 mostra estes três últimos conjuntos criados:

Quadro 9 – Outros conjuntos referente aos dois sinais.

Nº	Conjunto	Descrição
23	Os 50 pontos antes e os 50 depois dos Picos da Aplanação junto com o	Os 50 pontos antes e os 50 depois dos dois picos da aplanação e o valor do pico mais o

<p>+ posição do pico da pressão + posição do pico 1 + posição do pico 2 + valor do pico da pressão</p>	<p>valor do pico da pressão mais o valor das posições dos dois picos da aplanção para cada paciente. Total de 104 pontos = 101 pontos da aplanção + 3 pontos da pressão. (total de 102 aplanção + 2 posições picos + 1 valor pico pressão).</p>
<p>24 O valor das posições: -50, -25, o pico, 25 e 50 antes e depois dos Picos da Aplanção junto com a posição do pico da pressão + posição do pico 1 + posição do pico 2 + valor do pico da pressão</p>	<p>Os valores das posições 50 e 25 antes e depois de cada pico da aplanção mais o valor de cada pico da aplanção mais o valor do pico da pressão e a posição de cada um desse pontos. Total de 22 pontos.</p>
<p>25 Convolução dos 50 pontos antes e depois dos picos da aplanção com os pontos da pressão dos mesmos momentos</p>	<p>Convolução de sinais é o cálculo da área da união entre dois sinais.</p>

Fonte: Autora,2013.

Para cada um destes 25 conjuntos de pontos foram desenvolvidos 3 modelos computacionais baseados em aprendizagem de máquina, utilizando as representações do conhecimento já citadas: Árvore de decisão e Redes Neurais dos tipos MLP e RBF. Totalizando mais de 70 modelos computacionais preditivos.

Após a análise foi possível concluir quais conjuntos representavam maior importância para o problema.

Com estes conjuntos mais relevantes definidos foi possível explorá-los utilizando a decomposição wavelet, esta exploração foi realizada na segunda fase deste experimento que será descrita a seguir.

5.2 Decomposição Wavelet (Fase 2)

Esta fase tem o objetivo de realizar a decomposição wavelet dos conjuntos considerados mais relevantes na primeira fase deste experimento e observar se existirá melhora de resultados após as decomposições.

A decomposição wavelet pode ser realizada várias vezes e gera dois novos sinais a cada decomposição (aproximações e detalhes) e existem vários tipos de wavelets que podem ser utilizadas na decomposição.

Cada um dos sinais considerados relevantes na primeira fase foram decompostos 5 vezes, quantidade suficiente para os sinais propostos, pois a cada decomposição o sinal gerado tem quantidade de pontos reduzida a metade do sinal original.

Utilizando mais que 5 decomposições maioria dos sinais que foram processados ficariam com uma quantidade de pontos muito pequena, deixando o sinal inutilizável para os demais procedimentos deste experimento.

Quanto os tipos de wavelets, foram utilizadas as famílias Haar, Coiflets e Daubechies para observar a resposta de diversos tipos de wavelets neste problema. A ferramenta utilizada para a decomposição foi o Matlab.

O “Conjunto 8 - Os 50 pontos antes e os 50 depois de cada um dos dois picos da Aplanção” foi considerado um dos mais relevantes dos testes realizados na fase 1 de estudo geral dos sinais de pressão e aplanção. O Quadro 10 a seguir relembra este conjunto:

Quadro 10 – Conjunto 8 destaque.

Nº	Conjunto	Descrição
8	Os 50 pontos antes e os 50 depois de cada um dos dois picos da Aplanção	Os 50 pontos antes e os 50 pontos depois de cada um dos dois picos da Aplanção e os valores de cada pico de cada paciente. Total de 202 pontos.

Fonte: Autora,2013.

Iniciando a decomposição pelo tipo de wavelet Haar após a decomposição existiam agora 5 aproximações e 5 detalhes gerados a partir do sinal do Conjunto 8, ver Quadro 11:

Quadro 11 – Decomposição wavelet Haar do conjunto 8.

Sinal Original	Decomposição	Sinais gerados	Quant Pontos
Conjunto 8 (202 pontos)	Haar	Aproximação 1	101
		Aproximação 2	51
		Aproximação 3	26
		Aproximação 4	13
		Aproximação 5	7
		Detalhe 1	101
		Detalhe 2	51
		Detalhe 3	26
		Detalhe 4	13
		Detalhe 5	7

Fonte: Autora,2013.

No início observou-se o desempenho de todos os sinais gerados pela decomposição, então executou-se os algoritmos de classificação MLP e RBF em todos os dez sinais gerados, todas as aproximações e detalhes.

Após os processamentos percebeu-se que os detalhes realmente são ruídos e não apresentam bons resultados, apenas foram processados para efeito de teste.

Então a decomposição do Conjunto 8 prosseguiu como os tipos de wavelet: Coiflets 1, Coiflets 5, Daubechies 5 e Daubechies 10. Novamente foram utilizadas 5 decomposições, mas foram analisados agora apenas as aproximações, ver Quadro 12:

Quadro 12– Decomposição wavelet Coiflets 1, Coiflets 5, Daubechies 5 e Daubechies 10 do conjunto 8.

Sinal	Decomposição	Sinais gerados
Conjunto 8	Coiflets 1	Aproximação 1
		Aproximação 2
		Aproximação 3
		Aproximação 4
		Aproximação 5
	Coiflets 5	Aproximação 1
		Aproximação 2
		Aproximação 3
		Aproximação 4
		Aproximação 5
	Daubechies 5	Aproximação 1
		Aproximação 2
		Aproximação 3
		Aproximação 4
		Aproximação 5
	Daubechies 10	Aproximação 1
		Aproximação 2
		Aproximação 3
		Aproximação 4
		Aproximação 5

Fonte: Autora,2013.

Cada um dos 20 sinais gerados a partir da decomposição foram processados pelos algoritmos MLP e RBF gerando novos modelos computacionais que tiveram seus resultados analisados.

Com a intenção de avaliar se a presença da pressão melhoraria os resultados, os conjuntos “Conjunto 17 - Os 50 pontos antes e os 50 depois dos dois picos da Aplanção junto com os valores da pressão das mesmas posições” e “Conjunto 25 - Convolução dos 50 pontos antes e depois dos picos da aplanção com os pontos da pressão dos mesmos momentos” foram também processados,

pois acrescentam os pontos da pressão ao Conjunto 8 de formar diferentes, ver Quadro 13 a seguir:

Quadro 13 – Conjuntos 17 e 25 destaques contendo pontos da pressão.

Nº	Conjunto	Descrição
17	Os 50 pontos antes e os 50 depois dos dois picos da Aplanção junto com os valores da pressão das mesmas posições	Os 50 pontos antes e os 50 depois dos dois picos da aplanção e o valor do pico mais os valores da pressão das mesmas posições dos valores da aplanção de cada paciente. Total de 404 pontos = 202 pontos da aplanção + 202 pontos da pressão.
25	Convolução dos 50 pontos antes e depois dos picos da aplanção com os pontos da pressão dos mesmos momentos	Convolução de sinais é o cálculo da área da união entre dois sinais.

Fonte: Autora,2013.

Foram identificadas as decomposições que tiveram os melhores resultados nos experimentos com o conjunto 8 e estas forma processadas também para os conjuntos 17 e 25. Ver Quadro 14 a seguir:

Quadro 14 – Decomposições wavelets conjuntos 17.

Sinal	Decomposições
Conjunto 17	Aproximação 3 da decomposição Haar
	Aproximação 3 da decomposição Coiflets 1
	Aproximação 1 da decomposição Coiflets 5
	Aproximação 1 da decomposição Daubechies 10
Conjunto 25	Aproximação 3 da decomposição Haar
	Aproximação 3 da decomposição Coiflets 1
	Aproximação 1 da decomposição Coiflets 5
	Aproximação 1 da decomposição Daubechies 10

Fonte: Autora,2013.

Os quatro novos sinais gerados também foram processados pelos algoritmos MPL e RBF criando doze novos modelos computacionais que foram comparados com todos os demais existentes.

Após a criação, teste e comparação de todos esses modelos computacionais foi possível explorar bem e conhecer os dois sinais de aplanção e pressão na primeira fase “Estudo geral dos sinais de pressão e aplanção” e realizar a decomposição wavelet dos sinais mais relevantes na fase 2 “Decomposição

Wavelet”, identificando os modelos que geraram mais acertos para contribuir na decisão do cirurgião refrativo.

A sessão a seguir apresenta os melhores resultados encontrados nas duas fases.

6 RESULTADOS E DISCUSSÕES

Após todos os processamentos haviam 72 resultados da "Fase 1 - Estudo geral dos sinais de pressão e aplanção", mais 76 da "Fase 2 – Decomposição Wavelet", totalizando 148 resultados. Devido a grande quantidade de resultados o objetivo desta sessão é apresentar os melhores de cada etapa com suas discussões. Para ver todos os resultados do experimento favor consultar o Apêndice A – Todos os resultados encontrados.

O modo definido para apresentar os resultados foi a matriz de confusão, pois facilita a comparação e proporciona os cálculos de várias taxas para avaliar o desempenho dos algoritmos. Como só existem duas classes serão utilizadas as fórmulas já apresentadas na sessão 4.4 neste trabalho.

6.1 Melhores Resultados Fase 1 – Estudo Geral dos Sinais de Pressão e Aplanção

Relembrando, na Fase 1 foram analisados os sinais em várias perspectivas para conhecê-los, individualmente ou os unindo em 25 conjuntos que foram utilizados cada um deles para treino e teste dos três algoritmos de AM: Árvore de decisão, MLP e RBF.

De todos os 72 modelos gerados nesta fase, três tiveram destaque em seus resultados e criados a partir dos seguinte conjuntos: “Conjunto 8 – Os 50 pontos antes e os 50 depois de cada um dos dois picos da aplanção”, “Conjunto 17 - Os 50 pontos antes e os 50 depois dos dois picos da Aplanção junto com os valores da pressão das mesmas posições” e “Conjunto 25 - Convolução dos 50 pontos antes e depois dos picos da aplanção com os pontos da pressão dos mesmos momentos”.

Os Conjunto 8 e 17 processados com a rede neural do tipo MLP apresentaram os melhores resultados da primeira fase em relação a taxa de acerto total com 92,54% e 91,04% respectivamente, ver matriz de confusão na Figura 23 e Figura 24 a seguir:

Figura 23 – Matriz de confusão após processamento da rede neural MLP no conjunto 8.

accuracy: 92.52% +/- 6.03% (mikro: 92.54%)			
	true KK	true NORMAL	class precision
pred. KK	55	5	91.67%
pred. NORMAL	10	131	92.91%
class recall	84.62%	96.32%	

Fonte: Autora, 2013.

Figura 24 – Matriz de confusão após processamento da rede neural MLP no conjunto 17.

accuracy: 91.02% +/- 6.65% (mikro: 91.04%)			
	true KK	true NORMAL	class precision
pred. KK	55	8	87.30%
pred. NORMAL	10	128	92.75%
class recall	84.62%	94.12%	

Fonte: Autora, 2013.

Outra taxa importante quando se lida com problemas da área saúde é a sensibilidade. Estes resultados não apresentam um bom resultado em relação a essa taxa, com apenas 84,62%, também em destaque nas figuras 23 e 24.

Com relação à sensibilidade, os melhores resultados da primeira parte foram obtidos com o algoritmo rede neural RBF aplicado nos conjuntos 8 e 25. Ambos alcançando uma taxa de 92,31% de sensibilidade, ver Figura 25 e Figura 26.

Figura 25 – Matriz de confusão após processamento da rede neural RBF no conjunto 8.

accuracy: 88.57% +/- 4.45% (mikro: 88.56%)			
	true KK	true NORMAL	class precision
pred. KK	60	18	76.92%
pred. NORMAL	5	118	95.93%
class recall	92.31%	86.76%	

Fonte: Autora,2013.

Figura 26 – Matriz de confusão após processamento da rede neural RBF no conjunto 25.

accuracy: 78.14% +/- 5.82% (mikro: 78.11%)			
	true KK	true NORMAL	class precision
pred. KK	60	39	60.61%
pred. NORMAL	5	97	95.10%
class recall	92.31%	71.32%	

Fonte: Autora,2013.

Percebe-se que dos 65 casos totais de ceratocone leves, que apenas 5 não foram identificados corretamente pelos dois modelos criados. Tal fato indicou que os pontos de pressão contribuem para o aumento da sensibilidade.

Com os resultados aqui apresentados, conclui-se que os modelos encontrados já podem servir de base para uma ferramenta de auxílio para o cirurgião refrativo.

Dando continuidade a metodologia adotada, serão apresentados a seguir os resultados obtidos com o auxílio das técnicas de processamento de sinal.

6.2 Melhores Resultados Fase 2 – Decomposição Wavelet

Aplicando a técnica de decomposição Wavelet nos conjuntos de pontos identificados como melhores na primeira fase foram encontrados também ótimas taxas.

Para a taxa de acerto nos primeiros experimentos desta fase, sem a presença da pressão, foi encontrado uma acurácia total de 92,54%. Este resultado foi obtido utilizando o algoritmo de rede neural MLP no sinal da aproximação, decomposto 4 vezes pelo tipo de wavelet Haar. Tendo como sinal original o “Conjunto 8 – Os 50 pontos antes e os 50 depois de cada um dos dois picos da aplanção”, ver Figura 27.

Figura 27 – Matriz de confusão após processamento da rede neural MLP da aproximação 4 com wavelet do tipo Haar no Conjunto 8.

accuracy: 92.55% +/- 5.10% (mikro: 92.54%)			
	true KK	true NORMAL	class precision
pred. KK	58	8	87.88%
pred. NORMAL	7	128	94.81%
class recall	89.23%	94.12%	

Fonte: Autora,2013.

Apesar da acurácia ser a mesma encontrada na primeira fase, é importante destacar que o sinal da aproximação 4 do Conjunto 8 possui apenas 13 pontos em vez dos 202 utilizados na primeira fase. Isto reduziu de 12 minutos para 5 segundos, o tempo de processamento do algoritmo rede neural MLP.

Incluindo os valores do sinal de pressão, encontrou-se uma taxa de acerto de 93,03%, valor ainda melhor do que foi encontrado na primeira fase. O “Conjunto 17 - Os 50 pontos antes e os 50 depois dos dois picos da Aplanção junto com os valores da pressão das mesmas posições” foi decomposto 3 vezes pela wavelet Haar e sua aproximação processada pela rede neural MLP, ver Figura 28.

Figura 28 – Matriz de confusão após processamento da rede neural MLP da aproximação 3 com wavelet do tipo Haar do conjunto 17.

accuracy: 93.00% +/- 4.58% (mikro: 93.03%)			
	true KK	true NORMAL	class precision
pred. KK	57	6	90.48%
pred. NORMAL	8	130	94.20%
class recall	87.69%	95.59%	

Fonte: Autora,2013.

Quanto a sensibilidade, a aplicação do processamento de sinais também melhorou os resultados obtidos na primeira fase. Nesta fase, foi alcançada uma sensibilidade de 93,85%.

O Conjunto 8 decomposto uma vez pelas wavelets Daubechies 10 e Coiflets 5, utilizando o algoritmo rede neural MLP, criam modelos que têm como resultado uma taxa de sensibilidade de 93,85% ver Figuras 29 e Figuras 30.

Figura 29 – Matriz de confusão após processamento da rede neural MLP da aproximação 1 com wavelet do tipo Db10 no conjunto 8.

accuracy: 88.07% +/- 5.97% (mikro: 88.06%)			
	true KK	true NORMAL	class precision
pred. KK	61	20	75.31%
pred. NORMAL	4	116	96.67%
class recall	93.85%	85.29%	

Fonte: Autora,2013.

Figura 30 – Matriz de confusão após processamento da rede neural MLP da aproximação 1 com wavelet do tipo Coif5 no conjunto 8.

accuracy: 88.07% +/- 5.97% (mikro: 88.06%)			
	true KK	true NORMAL	class precision
pred. KK	61	20	75.31%
pred. NORMAL	4	116	96.67%
class recall	93.85%	85.29%	

Fonte: Autora,2013.

Neste caso a inclusão dos valores dos pontos de pressão não influenciou a sensibilidade. O resultado não se alterou, permanecendo em 93,85% na aproximação da terceira decomposição do “Conjunto 25 - Convolução dos 50 pontos antes e depois dos picos da aplanção com os pontos da pressão dos mesmos momentos” pelo tipo de wavelet Coiflets 1 utilizando a rede neural MLP, ver Figura 31.

Figura 31 – Matriz de confusão após processamento da rede neural MLP da aproximação 3 com wavelet do tipo Coif1 no conjunto 25.

accuracy: 78.64% +/- 5.29% (mikro: 78.61%)			
	true KK	true NORMAL	class precision
pred. KK	61	39	61.00%
pred. NORMAL	4	97	96.04%
class recall	93.85%	71.32%	

Fonte: Autora,2013.

Quanto a especificidade, o melhor resultado conseguido foi de 99,26%. Isso aconteceu utilizando a rede neural RBF na aproximação da terceira decomposição

do sinal do “Conjunto 8 – Os 50 pontos antes e os 50 depois de cada um dos dois picos da aplanção” processado pelo tipo de wavelet Coiflets 1, ver Figura 32.

Figura 32 – Matriz de confusão após processamento da rede neural RBF da aproximação 3 com wavelet do tipo Coif1 no conjunto 8.

accuracy: 86.05% +/- 6.66% (mikro: 86.07%)			
	true KK	true NORMAL	class precision
pred. KK	38	1	97.44%
pred. NORMAL	27	135	83.33%
class recall	58.46%	99.26%	

Fonte: Autora,2013.

Com os resultados desta fase, pode-se concluir que a utilização do processamento de sinais melhora o desempenho dos modelos preditivos. Mesmo a taxa de acerto permanecendo a mesma, é claramente percebido o aumento das taxas de sensibilidade e especificidade. Sendo a sensibilidade mais importante, pois está diretamente relacionada com os casos que poderão desenvolver a ectasia após a cirurgia refrativa.

Na sessão a seguir serão apresentadas as conclusões finais e os possíveis trabalhos futuros.

7 CONCLUSÃO E TRABALHOS FUTUROS

O desenvolvimento tecnológico tem auxiliado cirurgião refrativo nas últimas décadas. Recentemente surgiu mais um método de análise da córnea, que a observa em movimento visando a captura e suas propriedades biomecânicas.

A importância da biomecânica da córnea para cirurgia refrativa já é reconhecida pelos oftalmologistas, contudo ainda não há um meio preciso e de fácil utilização que auxilie o médico na detecção de casos suscetíveis baseados na biomecânica.

O presente trabalho se propôs a desenvolver modelos computacionais, através da inteligência artificial e utilizar a técnica de processamento de sinais wavelet, para analisar os parâmetros biomecânicos da córnea com a intenção de auxiliar o cirurgião refrativo em sua tomada de decisão.

Para o desenvolvimento deste modelo foram utilizados os sinais de aplanção e pressão provenientes do exame ORA. Estes sinais foram analisados e processados de diversas maneiras, e o estudo dividido em duas fases.

Na Fase 1 - Estudo geral dos sinais de pressão e aplanção, foi identificado como partes mais relevantes os dois picos da aplanção e os pontos próximos a estes, elegendo como um dos conjuntos mais relevantes o “Conjunto 8 – Os 50 pontos antes e os 50 depois de cada um dos dois picos da aplanção”.

O modelo computacional criado com base neste conjunto obteve bons resultados, comprovando que as áreas dos picos da aplanção são muito importantes para detecção de ceratocone em casos leves.

Já utilizando o sinal da pressão em conjunto com a aplanção os resultados foram melhores que utilizando apenas o sinal da aplanção. Os modelos que se destacam quanto a essa combinação dos dois sinais são: “Conjunto 17 - Os 50 pontos antes e os 50 depois dos dois picos da Aplanção junto com os valores da pressão das mesmas posições” e “Conjunto 25 - Convolução dos 50 pontos antes e depois dos picos da aplanção com os pontos da pressão dos mesmos momentos”.

Como conclusão da Fase 1 - Estudo geral dos sinais de pressão e aplanção tem-se que ambos os sinais são relevantes e que a região dos picos da aplanção são os mais importantes para este problema. Os conjuntos que representam os melhores resultados são os Conjuntos 8, 17 e 25 já citados anteriormente.

Estes conjuntos considerados mais relevantes na primeira fase do experimento, foram utilizados como base para o processamento de sinais wavelet na Fase 2 – Decomposição Wavelet. Com as decomposições as taxas de acertos, sensibilidade e especificidade foram melhoradas.

O modelo criado utilizando a rede neural MLP e terceira decomposição wavelet Haar com o “Conjunto 17 - Os 50 pontos antes e os 50 depois dos dois picos da Aplanção junto com os valores da pressão das mesmas posições” obteve a melhor taxa de acerto entre todos os modelos criados, 93,03%.

A taxa de sensibilidade chegou a 93,85% por mais de um modelo criado, utilizando processamento de sinais e os conjuntos: “Conjunto 8 – Os 50 pontos antes e os 50 depois de cada um dos dois picos da aplanção” e “Conjunto 25 - Convolução dos 50 pontos antes e depois dos picos da aplanção com os pontos da pressão dos mesmos momentos”.

A melhor taxa de especificidade conseguida foi de 99,26% utilizando a rede neural RBF na terceira decomposição Coiflets 1 do “Conjunto 8 – Os 50 pontos antes e os 50 depois de cada um dos dois picos da aplanção”.

Nos experimentos realizados, os modelos desenvolvidos possuem fortes indicações para auxiliar o cirurgião refrativo em seu dia a dia, mas para isso seria necessário levar este(s) modelo(s) computacional(is) para uma aplicação intuitiva que permita ao médico a sua utilização.

Como visto, as melhores taxas encontradas estão em modelos diferentes. No momento da construção da ferramenta de auxílio a tomada de decisão médica, seria interessante reunir todas estes resultados em um modelo único ou em um modelo composto. Também unir a dados clínicos, dados resultantes de exames de imagens e melhores resultados de outras pesquisas do grupo BrAIIn. Assim atingindo o objetivo de contribuir para com o cirurgião em sua decisão quanto a realização ou não da cirurgia refrativa em casos suspeitos.

O presente trabalho recebeu apoio financeiro da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) por meio de bolsa de estudo.

REFERÊNCIAS

ANDRADE, G. S. **Uso de Wavelets para a melhoria de desempenho de simulações numéricas usando carregamentos de pistas da indústria automotiva**. 2009. 93 f. Dissertação (Mestrado em Mecatônica)–Universidade Federal da Bahia, Bahia, 2009.

ANG, E.K. et al. Outcomes of laser refractive surgery for myopia. **Journal of Cataract & Refractive Surgery**, Australia, v. 35, n. 5, p. 921-933, may 2009.

ARAUJO, M. S. **Influência de famílias wavelets e suas ordens no desempenho de um localizador de faltas em linhas aéreas de transmissão de energia elétrica**. 2011. 207 f. Dissertação (Mestrado em Engenharia Elétrica) –Universidade Federal do Pará, Pará, 2011.

ARNTZ, A; DURAN, J. A.; PIJOAN, J. I. Subclinical keratoconus diagnosis by elevation topography. **Arch Soc Esp Oftalmol**, Madrid, v. 78, n. 12, dec. 2003. Disponível em: <http://scielo.isciii.es/scielo.php?script=sci_arttext&pid=S0365-66912003001200005&lng=en&nrm=iso>. Acesso em: 10 mar. 2013. <http://dx.doi.org/10.4321/S0365-66912003001200005>.

BELIN, M. W. et al. Keratoconus/ectasia detection with the Oculus Pentacam: Belin/Ambrósio enhanced ectasia display. **Oculus**, Germany, v. 35, n. 6, p. 3-7, [2007?]. Disponível em: <http://www.oculus.de/en/downloads/dyn/oculus/presse/158/oculus_low_res.pdf> Acesso em: 10 mar. 2013.

BELIN, M. W.; AMBROSIO, R. J. The Belin/Ambrósio Enhanced Extasia Display. **The News Magazine Of the Asia-Pacific Association of Cataract & Refractive Surgeons (APACRS)**, United States, v. 6, n. 2, june 2010.

BINDER, P. S. Analysis of ectasia after laser in situ keratomileusis: Risk factors. **Journal of Cataract & Refractive Surgery**, United States, v. 33, n. 9, p. 1530-1538, sept. 2007.

BORS, A. G. Introduction of the Radial Basis Function (RBF) Networks. **Online Symposium for Electronics Engineers**. United States, v.1, n. 1, p. 1-7 feb. 2001. Disponível em: <<http://www-users.cs.york.ac.uk/adrian/Papers/Others/OSEE01.pdf>>. Acesso em: 12 mar. 2013.

CONSELHO BRASILEIRO DE OFTALMOLOGIA. **Ceratocone**. São Paulo, [entre 2011 e 2013]. Disponível em: <http://www.cbo.com.br/novo/publico_geral/doencas/ceratocone>. Acesso em: 10 fev. 2013.

CONSELHO REGIONAL DE ÓPTICA E OPTOMETRIA. **Dicionário de Optometria Elena Gelado**. São Paulo, [2010?]. Disponível em: <http://www.croosp.org.br/work/eg/Dicionario_EG_C_.pdf>. Acesso em: 16 fev. 2013.

DEPARTAMENTO DE INFORMÁTICA EM SAÚDE DA UNIFESP. **Histórico Detalhado**. São Paulo, [entre 2008 e 2013]. Disponível em: <<http://www.unifesp.br/dis/historico/historico-detalhado>>. Acesso em: 16 fev. 2013.

DEPARTMENT OF CYBERNETICS. **Wavelet theory**. Czech Republic, [entre 1996 e 2013]. Disponível em: <http://cyber.felk.cvut.cz/gerstner/biolab/bio_web/teach/FunBio/wavelets.html>. Acesso em: 13 mar. 2013.

FACELI, K. et al. **Inteligência Artificial: Uma abordagem de Aprendizagem de Máquina**. Rio de Janeiro: LTC, 2011.

FARIAS, R. R. A. **Aplicação de Wavelets Na Análise de Gestos Musicais Em Timbres de Instrumentos Acústicos Tradicionais**. 1997. 203 f. Dissertação (Mestrado em Engenharia de Sistemas Eletrônicos) –Universidade de São Paulo, São Paulo, 1997.

FONDATION OPHTALMOLOGIQUE ADOLPHE DE ROTHSCHILD. **Fondation Ophthalmologique Adolphe de Rothschild**. France, [2013?]. Disponível em: <<http://www.fo-rothschild.fr/soins/ophtalmologie/chirurgie-refractive.html>>. Acesso em: 12 mar. 2013.

GLASS, D. H. **Characterization of the biomechanical properties of the in vivo human cornea**. 2008. 84 f. Thesis (Doctor of Philosophy in the Graduate) –Ohio State University, United States, 2008.

GROTTONE, G. T. et al. Desenvolvimento de software oftalmológico para computação móvel. **Arquivos Brasileiros de Oftalmologia**, São Paulo, v.69, n. 4, p. 487-490, jul. 2006.

LABORATÓRIO DE PROCESSAMENTO DIGITAL DE SINAIS E IMAGENS. **Processamento de Sinais**. Rio de Janeiro, [entre 2008 e 2013]. Disponível em: <<http://www.cbpf.br/cat/pdsi/>>. Acesso em: 26 fev. 2013.

LIMA, C. A. **Proposição e teste de um questionário sobre qualidade de vida em pacientes com ceratocone**. 2000. 99 f. Dissertação (Mestrado em Ciências Médicas) –Faculdade de Ciências Médica da Universidade Estadual de Campinas, São Paulo, 2000.

LYRA, J. M. A. G. et al. Applications or Artificial Intelligence Techniques for Improving Tomographic Screening for Ectasia. In: BELIN, M.W.; KHACHIKIAN, S. S.; AMBROSIO, R. **Elevation Based Corneal Tomography**. 2. Ed. Panama: Jaypee-Highlights, 2012. p.123-134.

LYRA, J. M. A. G. **Utilização da radiofrequencia para o tratamento do ceratocone**. 2006. 169 f. Tese (Doutorado em Medicina) –Faculdade de Medicina da Universidade Federal de Minas Gerais, Minas Gerais, 2006.

MARTINS, A. C. O.; OLIVEIRA, T. D. P. **Topografia da córnea: Instrumentação Optoelectrónica**. 2011. 23 f. Dissertação (Mestrado Integrado em Engenharia Biomédica)–Faculdade de Ciências e Tecnologia da Universidade de Coimbra, Portugal, 2011.

MATHWORKS, **Wavelet Toolbox**. United States, [entre 1994 e 2013]. Disponível em:
<<http://www.mathworks.com/help/wavelet/index.html?/access/helpdesk/help/toolbox/wavelet>>. Acesso em: 12 fev. 2013.

MATHWORKS. **Rápido Transformada Wavelet (FWT) Algoritmo**. United States, [entre 1994 e 2013]. Disponível em:
<<http://www.mathworks.com/help/wavelet/ug/fast-wavelet-transform-fwt-algorithm.html>>. Acesso em: 12 fev. 2013.

MEDEIROS, F. W. **Alterações biomecânicas da córnea de suínos induzidas pela confecções de lamelas pediculadas de diferentes espessuras por laser de femtossegundo**. 2011. 70 f. Tese (Doutorado em Oftalmologia) –Faculdade de Medicina da Universidade de São Paulo, São Paulo.

MELLI, R. Expert Systems and Knowledge Acquisition. **Encyclopedia of Life Support Systems (EOLSS)**, United States, v. 3, [2002?]. Disponível em:
<<http://www.eolss.net/Sample-Chapters/C08/E3-19-04-02.pdf>>. Acesso em: 19 jun. 2013.

PENSIERO, S.; ACCARDO, P. Neural network-based system for early keratoconus detection from corneal topography. **Journal of Biomedical Informatics**, Italy, v. 35, n. 3, p. 151-159, June 2002.

PEREIRA, T.; FORSETO, A. S.; NOSE, W. Complicações per e pós-operatórias em 1000 olhos submetidos a LASIK. **Arquivos Brasileiros de Oftalmologia**, São Paulo, v. 64, n. 6, p. 499-506, nov. 2001.

QUINLAN, J. R. **C4.5: Programs for Machine Learning**. United States: Morgan Kaufmann Publishers Inc, 1993.

RAPIDMINER. **RapidMiner**. [United States], 2013. Disponível em: <<http://rapid-i.com/index.php?lang=en>>. Acessado em: 01 fev. 2013.

REICHERT TECHNOLOGIES. **Preserving Sight**. United States, [entre 2011 e 2013]. Disponível em:
<http://www.reichert.com/product_details.cfm?pclid=408&skuld=2976&skuTk=1036239258>. Acesso em: 18 fev. 2013.

REZENDE, S. O. **Sistemas Inteligentes: fundamentos e aplicações**. Barueri: Manole, 2005.

RUSSELL, S. J. NORVIG, P. **Inteligência Artificial**. 2. ed. Rio de Janeiro: Elsevier, 2004. Tradução de: PubliCare Consultoria.

SINJAB, M. M. **Quick Guide to the Management of Keratoconus: a systematic step-by-step approach**. [S.l.]:Springer, 2012.

SMOLEK, M.K. et al. Automated keratoconus screening with corneal topography analysis. **Investigative Ophthalmology & Visual Science**, United States, v. 35, n. 6, p. 2749-2757, May 1994.

SMOLEK, M.K.; KLYCE, S.D.; KARON, M.D. Screening patients with the corneal navigator. **Journal Refractive Surgery**, United States, v. 21, n. 5, p. 617-622, sept. 2005.

SOCIEDADE BRASILEIRA DE INFORMÁTICA EM SAÚDE, **A História da SBIS**. São Paulo, [2013?]. Disponível em: <<http://www.sbis.org.br/indexframe.html>>. Acesso em: 16 fev. 2013.

SOUZA, M. B. et al. Evaluation of machine learning classifiers in keratoconus detection from orbscan II examinations. **Clinics**, São Paulo, v. 65, n. 12, p. 1223-1228, sept. 2010.

THE UNIVERSITY OF WAIKATO, **Weka 3**: Data Mining Software in Java. New Zealand, [2013?]. Disponível em <<http://www.cs.waikato.ac.nz/ml/weka/>>. Acessado em: 01 fev. 2013.

VALBON, B. F. et al. Importância da tomografia de córnea para o diagnóstico de ectasia. **Revista Brasileira de Oftalmologia**, Rio de Janeiro, v. 71, n. 5, p. 302-308, set. 2012.

VENTURA, Bruna V. et al. Analysis of Waveform-Derived ORA Parameters in Early Forms of Keratoconus and Normal Corneas. **Journal of Refractive Surgery**, Rio de Janeiro, v. 29, n. 9, p. 637-643, sept. 2013.

APÊNDICE A – Todos os Resultados Encontrados

Nº	Conjunto	Representação Aprendizagem	Processamento de Sinais		
		Resultados			
1	Todos os pontos da Pressão	MLP	Não houve		
		accuracy: 83.05% +/- 6.46% (mikro: 83.08%)			
			true KK	true NORMAL	class precision
		pred. KK	45	14	76.27%
		pred. NORMAL	20	122	95.92%
		class recall	69.23%	89.71%	
		Árvore de decisão	Não houve		
		accuracy: 80.12% +/- 7.68% (mikro: 80.10%)			
			true KK	true NORMAL	class precision
pred. KK	38	13	74.51%		
pred. NORMAL	27	123	82.00%		
class recall	58.46%	90.44%			
RBF	Não houve				
accuracy: 79.17% +/- 7.72% (mikro: 79.10%)					
	true KK	true NORMAL	class precision		
pred. KK	50	27	64.94%		
pred. NORMAL	15	109	87.90%		
class recall	76.92%	80.15%			
2	Os 10 pontos antes e depois do pico da pressão	MLP	Não houve		
		accuracy: 80.07% +/- 8.99% (mikro: 80.10%)			
			true KK	true NORMAL	class precision
		pred. KK	39	14	73.58%
		pred. NORMAL	26	122	82.43%
		class recall	60.00%	89.71%	
		Árvore de decisão	Não houve		
		accuracy: 78.12% +/- 7.77% (mikro: 78.11%)			
			true KK	true NORMAL	class precision
pred. KK	27	6	81.82%		
pred. NORMAL	38	130	77.38%		
class recall	41.54%	95.59%			
RBF	Não houve				
accuracy: 79.60% +/- 10.12% (mikro: 79.60%)					
	true KK	true NORMAL	class precision		
pred. KK	39	15	72.22%		
pred. NORMAL	26	121	82.31%		
class recall	60.00%	88.97%			
3	Os 25 pontos antes e depois do pico da pressão	MLP	Não houve		
		accuracy: 80.05% +/- 10.77% (mikro: 80.10%)			
			true KK	true NORMAL	class precision
		pred. KK	38	13	74.51%
		pred. NORMAL	27	123	82.00%
		class recall	58.46%	90.44%	
		Árvore de decisão	Não houve		
		accuracy: 78.12% +/- 7.77% (mikro: 78.11%)			
			true KK	true NORMAL	class precision
pred. KK	31	10	75.61%		
pred. NORMAL	34	126	78.75%		
class recall	47.69%	92.65%			
RBF	Não houve				
accuracy: 79.60% +/- 10.12% (mikro: 79.60%)					
	true KK	true NORMAL	class precision		
pred. KK	39	15	72.22%		
pred. NORMAL	26	121	82.31%		
class recall	60.00%	88.97%			
4	Os 50 pontos antes e depois do pico da pressão	MLP	Não houve		
		accuracy: 78.57% +/- 9.81% (mikro: 78.61%)			
			true KK	true NORMAL	class precision
		pred. KK	36	14	72.00%
		pred. NORMAL	29	122	80.79%
class recall	55.38%	89.71%			
Árvore de decisão	Não houve				

		<table border="1"> <thead> <tr> <th colspan="4">accuracy: 78.10% +/- 8.45% (mikro: 78.11%)</th> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> </thead> <tbody> <tr> <td>pred. KK</td> <td>34</td> <td>13</td> <td>72.34%</td> </tr> <tr> <td>pred. NORMAL</td> <td>31</td> <td>123</td> <td>79.87%</td> </tr> <tr> <td>class recall</td> <td>52.31%</td> <td>90.44%</td> <td></td> </tr> </tbody> </table>	accuracy: 78.10% +/- 8.45% (mikro: 78.11%)					true KK	true NORMAL	class precision	pred. KK	34	13	72.34%	pred. NORMAL	31	123	79.87%	class recall	52.31%	90.44%		
accuracy: 78.10% +/- 8.45% (mikro: 78.11%)																							
	true KK	true NORMAL	class precision																				
pred. KK	34	13	72.34%																				
pred. NORMAL	31	123	79.87%																				
class recall	52.31%	90.44%																					
		<table border="1"> <thead> <tr> <th colspan="4">accuracy: 80.57% +/- 10.15% (mikro: 80.60%)</th> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> </thead> <tbody> <tr> <td>pred. KK</td> <td>39</td> <td>13</td> <td>75.00%</td> </tr> <tr> <td>pred. NORMAL</td> <td>26</td> <td>123</td> <td>82.55%</td> </tr> <tr> <td>class recall</td> <td>60.00%</td> <td>90.44%</td> <td></td> </tr> </tbody> </table>	accuracy: 80.57% +/- 10.15% (mikro: 80.60%)					true KK	true NORMAL	class precision	pred. KK	39	13	75.00%	pred. NORMAL	26	123	82.55%	class recall	60.00%	90.44%		
accuracy: 80.57% +/- 10.15% (mikro: 80.60%)																							
	true KK	true NORMAL	class precision																				
pred. KK	39	13	75.00%																				
pred. NORMAL	26	123	82.55%																				
class recall	60.00%	90.44%																					
5	Todos os pontos da Aplanação	MLP	Não houve																				
		<table border="1"> <thead> <tr> <th colspan="4">accuracy: 88.52% +/- 5.96% (mikro: 88.56%)</th> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> </thead> <tbody> <tr> <td>pred. KK</td> <td>53</td> <td>11</td> <td>82.81%</td> </tr> <tr> <td>pred. NORMAL</td> <td>12</td> <td>125</td> <td>91.24%</td> </tr> <tr> <td>class recall</td> <td>81.54%</td> <td>91.91%</td> <td></td> </tr> </tbody> </table>	accuracy: 88.52% +/- 5.96% (mikro: 88.56%)					true KK	true NORMAL	class precision	pred. KK	53	11	82.81%	pred. NORMAL	12	125	91.24%	class recall	81.54%	91.91%		
		accuracy: 88.52% +/- 5.96% (mikro: 88.56%)																					
			true KK	true NORMAL	class precision																		
		pred. KK	53	11	82.81%																		
		pred. NORMAL	12	125	91.24%																		
class recall	81.54%	91.91%																					
Árvore de decisão	Não houve																						
<table border="1"> <thead> <tr> <th colspan="4">accuracy: 90.50% +/- 6.87% (mikro: 90.55%)</th> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> </thead> <tbody> <tr> <td>pred. KK</td> <td>54</td> <td>8</td> <td>87.10%</td> </tr> <tr> <td>pred. NORMAL</td> <td>11</td> <td>128</td> <td>92.09%</td> </tr> <tr> <td>class recall</td> <td>83.08%</td> <td>94.12%</td> <td></td> </tr> </tbody> </table>	accuracy: 90.50% +/- 6.87% (mikro: 90.55%)					true KK	true NORMAL	class precision	pred. KK	54	8	87.10%	pred. NORMAL	11	128	92.09%	class recall	83.08%	94.12%				
accuracy: 90.50% +/- 6.87% (mikro: 90.55%)																							
	true KK	true NORMAL	class precision																				
pred. KK	54	8	87.10%																				
pred. NORMAL	11	128	92.09%																				
class recall	83.08%	94.12%																					
RBF	Não houve																						
<table border="1"> <thead> <tr> <th colspan="4">accuracy: 89.52% +/- 6.13% (mikro: 89.55%)</th> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> </thead> <tbody> <tr> <td>pred. KK</td> <td>55</td> <td>11</td> <td>83.33%</td> </tr> <tr> <td>pred. NORMAL</td> <td>10</td> <td>125</td> <td>92.59%</td> </tr> <tr> <td>class recall</td> <td>84.62%</td> <td>91.91%</td> <td></td> </tr> </tbody> </table>	accuracy: 89.52% +/- 6.13% (mikro: 89.55%)					true KK	true NORMAL	class precision	pred. KK	55	11	83.33%	pred. NORMAL	10	125	92.59%	class recall	84.62%	91.91%				
accuracy: 89.52% +/- 6.13% (mikro: 89.55%)																							
	true KK	true NORMAL	class precision																				
pred. KK	55	11	83.33%																				
pred. NORMAL	10	125	92.59%																				
class recall	84.62%	91.91%																					
6	Os 10 pontos antes e os 10 depois de cada um dos dois picos da Aplanação	MLP	Não houve																				
		<table border="1"> <thead> <tr> <th colspan="4">accuracy: 85.05% +/- 5.96% (mikro: 85.07%)</th> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> </thead> <tbody> <tr> <td>pred. KK</td> <td>50</td> <td>15</td> <td>76.92%</td> </tr> <tr> <td>pred. NORMAL</td> <td>15</td> <td>121</td> <td>88.97%</td> </tr> <tr> <td>class recall</td> <td>76.92%</td> <td>88.97%</td> <td></td> </tr> </tbody> </table>	accuracy: 85.05% +/- 5.96% (mikro: 85.07%)					true KK	true NORMAL	class precision	pred. KK	50	15	76.92%	pred. NORMAL	15	121	88.97%	class recall	76.92%	88.97%		
		accuracy: 85.05% +/- 5.96% (mikro: 85.07%)																					
			true KK	true NORMAL	class precision																		
		pred. KK	50	15	76.92%																		
		pred. NORMAL	15	121	88.97%																		
class recall	76.92%	88.97%																					
Árvore de decisão	Não houve																						
<table border="1"> <thead> <tr> <th colspan="4">accuracy: 84.62% +/- 8.07% (mikro: 84.58%)</th> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> </thead> <tbody> <tr> <td>pred. KK</td> <td>53</td> <td>19</td> <td>73.61%</td> </tr> <tr> <td>pred. NORMAL</td> <td>12</td> <td>117</td> <td>90.70%</td> </tr> <tr> <td>class recall</td> <td>81.54%</td> <td>86.03%</td> <td></td> </tr> </tbody> </table>	accuracy: 84.62% +/- 8.07% (mikro: 84.58%)					true KK	true NORMAL	class precision	pred. KK	53	19	73.61%	pred. NORMAL	12	117	90.70%	class recall	81.54%	86.03%				
accuracy: 84.62% +/- 8.07% (mikro: 84.58%)																							
	true KK	true NORMAL	class precision																				
pred. KK	53	19	73.61%																				
pred. NORMAL	12	117	90.70%																				
class recall	81.54%	86.03%																					
RBF	Não houve																						
<table border="1"> <thead> <tr> <th colspan="4">accuracy: 86.07% +/- 5.38% (mikro: 86.07%)</th> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> </thead> <tbody> <tr> <td>pred. KK</td> <td>52</td> <td>15</td> <td>77.61%</td> </tr> <tr> <td>pred. NORMAL</td> <td>13</td> <td>121</td> <td>90.30%</td> </tr> <tr> <td>class recall</td> <td>80.00%</td> <td>88.97%</td> <td></td> </tr> </tbody> </table>	accuracy: 86.07% +/- 5.38% (mikro: 86.07%)					true KK	true NORMAL	class precision	pred. KK	52	15	77.61%	pred. NORMAL	13	121	90.30%	class recall	80.00%	88.97%				
accuracy: 86.07% +/- 5.38% (mikro: 86.07%)																							
	true KK	true NORMAL	class precision																				
pred. KK	52	15	77.61%																				
pred. NORMAL	13	121	90.30%																				
class recall	80.00%	88.97%																					
7	Os 25 pontos antes e os 25 depois de cada um dos dois picos da Aplanação	MLP	Não houve																				
		<table border="1"> <thead> <tr> <th colspan="4">accuracy: 91.52% +/- 7.77% (mikro: 91.54%)</th> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> </thead> <tbody> <tr> <td>pred. KK</td> <td>54</td> <td>6</td> <td>90.00%</td> </tr> <tr> <td>pred. NORMAL</td> <td>11</td> <td>130</td> <td>92.20%</td> </tr> <tr> <td>class recall</td> <td>83.08%</td> <td>95.59%</td> <td></td> </tr> </tbody> </table>	accuracy: 91.52% +/- 7.77% (mikro: 91.54%)					true KK	true NORMAL	class precision	pred. KK	54	6	90.00%	pred. NORMAL	11	130	92.20%	class recall	83.08%	95.59%		
		accuracy: 91.52% +/- 7.77% (mikro: 91.54%)																					
			true KK	true NORMAL	class precision																		
		pred. KK	54	6	90.00%																		
		pred. NORMAL	11	130	92.20%																		
class recall	83.08%	95.59%																					
Árvore de decisão	Não houve																						
<table border="1"> <thead> <tr> <th colspan="4">accuracy: 84.55% +/- 9.63% (mikro: 84.58%)</th> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> </thead> <tbody> <tr> <td>pred. KK</td> <td>50</td> <td>16</td> <td>75.76%</td> </tr> <tr> <td>pred. NORMAL</td> <td>15</td> <td>120</td> <td>88.89%</td> </tr> <tr> <td>class recall</td> <td>76.92%</td> <td>88.24%</td> <td></td> </tr> </tbody> </table>	accuracy: 84.55% +/- 9.63% (mikro: 84.58%)					true KK	true NORMAL	class precision	pred. KK	50	16	75.76%	pred. NORMAL	15	120	88.89%	class recall	76.92%	88.24%				
accuracy: 84.55% +/- 9.63% (mikro: 84.58%)																							
	true KK	true NORMAL	class precision																				
pred. KK	50	16	75.76%																				
pred. NORMAL	15	120	88.89%																				
class recall	76.92%	88.24%																					
RBF	Não houve																						
<table border="1"> <thead> <tr> <th colspan="4">accuracy: 87.57% +/- 5.99% (mikro: 87.56%)</th> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> </thead> <tbody> <tr> <td>pred. KK</td> <td>57</td> <td>17</td> <td>77.03%</td> </tr> <tr> <td>pred. NORMAL</td> <td>8</td> <td>119</td> <td>93.70%</td> </tr> <tr> <td>class recall</td> <td>87.69%</td> <td>87.50%</td> <td></td> </tr> </tbody> </table>	accuracy: 87.57% +/- 5.99% (mikro: 87.56%)					true KK	true NORMAL	class precision	pred. KK	57	17	77.03%	pred. NORMAL	8	119	93.70%	class recall	87.69%	87.50%				
accuracy: 87.57% +/- 5.99% (mikro: 87.56%)																							
	true KK	true NORMAL	class precision																				
pred. KK	57	17	77.03%																				
pred. NORMAL	8	119	93.70%																				
class recall	87.69%	87.50%																					
8	Os 50 pontos	MLP	Não houve																				

antes e os 50
depois de
cada um dos
dois picos da
Aplanação

accuracy: 92.52% +/- 6.03% (mikro: 92.54%)			
	true KK	true NORMAL	class precision
pred. KK	55	5	91.67%
pred. NORMAL	10	131	92.91%
class recall	84.62%	96.32%	
Árvore de decisão	Não houve		
accuracy: 84.02% +/- 8.34% (mikro: 84.08%)			
	true KK	true NORMAL	class precision
pred. KK	48	15	76.19%
pred. NORMAL	17	121	87.68%
class recall	73.85%	88.97%	
RBF	Não houve		
accuracy: 88.57% +/- 4.45% (mikro: 88.56%)			
	true KK	true NORMAL	class precision
pred. KK	60	18	76.92%
pred. NORMAL	5	118	95.93%
class recall	92.31%	86.76%	
MLP	Haar Aproximação 1		
accuracy: 91.52% +/- 5.52% (mikro: 91.54%)			
	true KK	true NORMAL	class precision
pred. KK	53	5	91.38%
pred. NORMAL	12	131	91.61%
class recall	81.54%	96.32%	
RBF	Haar Aproximação 1		
accuracy: 88.57% +/- 4.45% (mikro: 88.56%)			
	true KK	true NORMAL	class precision
pred. KK	60	18	76.92%
pred. NORMAL	5	118	95.93%
class recall	92.31%	86.76%	
MLP	Haar Aproximação 2		
accuracy: 91.52% +/- 5.95% (mikro: 91.54%)			
	true KK	true NORMAL	class precision
pred. KK	54	6	90.00%
pred. NORMAL	11	130	92.20%
class recall	83.08%	95.59%	
RBF	Haar Aproximação 2		
accuracy: 88.57% +/- 4.45% (mikro: 88.56%)			
	true KK	true NORMAL	class precision
pred. KK	60	18	76.92%
pred. NORMAL	5	118	95.93%
class recall	92.31%	86.76%	
MLP	Haar Aproximação 3		
accuracy: 90.05% +/- 7.75% (mikro: 90.05%)			
	true KK	true NORMAL	class precision
pred. KK	53	8	86.89%
pred. NORMAL	12	128	91.43%
class recall	81.54%	94.12%	
RBF	Haar Aproximação 3		
accuracy: 89.02% +/- 5.86% (mikro: 89.05%)			
	true KK	true NORMAL	class precision
pred. KK	48	5	90.57%
pred. NORMAL	17	131	88.51%
class recall	73.85%	96.32%	
MLP	Haar Aproximação 4		
accuracy: 92.55% +/- 5.10% (mikro: 92.54%)			
	true KK	true NORMAL	class precision
pred. KK	58	8	87.88%
pred. NORMAL	7	128	94.81%
class recall	89.23%	94.12%	
RBF	Haar Aproximação 4		
accuracy: 90.57% +/- 5.61% (mikro: 90.55%)			
	true KK	true NORMAL	class precision
pred. KK	57	11	83.82%
pred. NORMAL	8	125	93.98%
class recall	87.69%	91.91%	
MLP	Haar Aproximação 5		

accuracy: 88.55% +/- 5.51% (mikro: 88.56%)			
	true KK	true NORMAL	class precision
pred. KK	52	10	83.87%
pred. NORMAL	13	126	90.65%
class recall	80.00%	92.65%	
RBF	Haar Aproximação 5		
accuracy: 88.57% +/- 3.13% (mikro: 88.56%)			
	true KK	true NORMAL	class precision
pred. KK	58	16	78.38%
pred. NORMAL	7	120	94.49%
class recall	89.23%	88.24%	
MLP	Haar Detalhe 1		
accuracy: 82.55% +/- 9.85% (mikro: 82.59%)			
	true KK	true NORMAL	class precision
pred. KK	48	18	72.73%
pred. NORMAL	17	118	87.41%
class recall	73.85%	86.76%	
RBF	Haar Detalhe 1		
accuracy: 84.62% +/- 8.07% (mikro: 84.58%)			
	true KK	true NORMAL	class precision
pred. KK	50	16	75.76%
pred. NORMAL	15	120	88.89%
class recall	76.92%	88.24%	
MLP	Haar Detalhe 2		
accuracy: 83.07% +/- 7.83% (mikro: 83.08%)			
	true KK	true NORMAL	class precision
pred. KK	53	22	70.67%
pred. NORMAL	12	114	90.48%
class recall	81.54%	83.82%	
RBF	Haar Detalhe 2		
accuracy: 86.62% +/- 9.09% (mikro: 86.57%)			
	true KK	true NORMAL	class precision
pred. KK	51	13	79.69%
pred. NORMAL	14	123	89.78%
class recall	78.46%	90.44%	
MLP	Haar Detalhe 3		
accuracy: 85.05% +/- 4.53% (mikro: 85.07%)			
	true KK	true NORMAL	class precision
pred. KK	47	12	79.66%
pred. NORMAL	18	124	87.32%
class recall	72.31%	91.18%	
RBF	Haar Detalhe 3		
accuracy: 87.02% +/- 8.15% (mikro: 87.06%)			
	true KK	true NORMAL	class precision
pred. KK	44	5	89.80%
pred. NORMAL	21	131	86.18%
class recall	67.69%	96.32%	
MLP	Haar Detalhe 4		
accuracy: 87.57% +/- 7.48% (mikro: 87.56%)			
	true KK	true NORMAL	class precision
pred. KK	49	9	84.48%
pred. NORMAL	16	127	88.81%
class recall	75.38%	93.38%	
RBF	Haar Detalhe 4		
accuracy: 87.07% +/- 6.38% (mikro: 87.06%)			
	true KK	true NORMAL	class precision
pred. KK	59	20	74.68%
pred. NORMAL	6	116	95.08%
class recall	90.77%	85.29%	
MLP	Haar Detalhe 5		
accuracy: 88.57% +/- 3.85% (mikro: 88.56%)			
	true KK	true NORMAL	class precision
pred. KK	53	11	82.81%
pred. NORMAL	12	125	91.24%
class recall	81.54%	91.91%	
RBF	Haar Detalhe 5		

accuracy: 86.07% +/- 8.60% (mikro: 86.07%)			
	true KK	true NORMAL	class precision
pred. KK	54	17	76.06%
pred. NORMAL	11	119	91.54%
class recall	83.08%	87.50%	
MLP	Coiflets 1 Aproximação 1		
accuracy: 92.02% +/- 6.01% (mikro: 92.04%)			
	true KK	true NORMAL	class precision
pred. KK	54	5	91.53%
pred. NORMAL	11	131	92.25%
class recall	83.08%	96.32%	
RBF	Coiflets 1 Aproximação 1		
accuracy: 88.07% +/- 4.54% (mikro: 88.06%)			
	true KK	true NORMAL	class precision
pred. KK	60	19	75.95%
pred. NORMAL	5	117	95.90%
class recall	92.31%	86.03%	
MLP	Coiflets 1 Aproximação 2		
accuracy: 92.52% +/- 4.62% (mikro: 92.54%)			
	true KK	true NORMAL	class precision
pred. KK	56	6	90.32%
pred. NORMAL	9	130	93.53%
class recall	86.15%	95.59%	
RBF	Coiflets 1 Aproximação 2		
accuracy: 87.57% +/- 5.56% (mikro: 87.56%)			
	true KK	true NORMAL	class precision
pred. KK	60	20	75.00%
pred. NORMAL	5	116	95.87%
class recall	92.31%	85.29%	
MLP	Coiflets 1 Aproximação 3		
accuracy: 91.02% +/- 5.85% (mikro: 91.04%)			
	true KK	true NORMAL	class precision
pred. KK	56	9	86.15%
pred. NORMAL	9	127	93.38%
class recall	86.15%	93.38%	
RBF	Coiflets 1 Aproximação 3		
accuracy: 87.10% +/- 5.89% (mikro: 87.06%)			
	true KK	true NORMAL	class precision
pred. KK	52	13	80.00%
pred. NORMAL	13	123	90.44%
class recall	80.00%	90.44%	
MLP	Coiflets 1 Aproximação 4		
accuracy: 91.05% +/- 5.82% (mikro: 91.04%)			
	true KK	true NORMAL	class precision
pred. KK	55	8	87.30%
pred. NORMAL	10	128	92.75%
class recall	84.62%	94.12%	
RBF	Coiflets 1 Aproximação 4		
accuracy: 89.02% +/- 7.70% (mikro: 89.05%)			
	true KK	true NORMAL	class precision
pred. KK	47	4	92.16%
pred. NORMAL	18	132	88.00%
class recall	72.31%	97.06%	
MLP	Coiflets 1 Aproximação 5		
accuracy: 88.55% +/- 6.74% (mikro: 88.56%)			
	true KK	true NORMAL	class precision
pred. KK	53	11	82.81%
pred. NORMAL	12	125	91.24%
class recall	81.54%	91.91%	
RBF	Coiflets 1 Aproximação 5		
accuracy: 81.62% +/- 6.23% (mikro: 81.59%)			
	true KK	true NORMAL	class precision
pred. KK	58	30	65.91%
pred. NORMAL	7	106	93.81%
class recall	89.23%	77.94%	
MLP	Coiflets 5 Aproximação 1		
accuracy: 92.02% +/- 6.41% (mikro: 92.04%)			
	true KK	true NORMAL	class precision
pred. KK	55	6	90.18%
pred. NORMAL	10	130	92.86%
class recall	84.62%	95.59%	

		RBF		Coiflets 5 Aproximação 1		
		accuracy: 88.07% +/- 5.97% (mikro: 88.06%)				
			true KK	true NORMAL	class precision	
		pred. KK	61	20	75.31%	
		pred. NORMAL	4	116	96.67%	
		class recall	93.85%	85.29%		
		MLP		Coiflets 5 Aproximação 2		
		accuracy: 91.02% +/- 6.65% (mikro: 91.04%)				
			true KK	true NORMAL	class precision	
		pred. KK	54	7	88.52%	
		pred. NORMAL	11	129	92.14%	
		class recall	83.08%	94.85%		
		RBF		Coiflets 5 Aproximação 2		
		accuracy: 85.57% +/- 6.10% (mikro: 85.57%)				
			true KK	true NORMAL	class precision	
		pred. KK	60	24	71.43%	
		pred. NORMAL	5	112	95.73%	
		class recall	92.31%	82.35%		
		MLP		Coiflets 5 Aproximação 3		
		accuracy: 90.52% +/- 8.51% (mikro: 90.55%)				
	true KK	true NORMAL	class precision			
pred. KK	55	9	85.94%			
pred. NORMAL	10	127	92.70%			
class recall	84.62%	93.38%				
RBF		Coiflets 5 Aproximação 3				
accuracy: 78.14% +/- 6.63% (mikro: 78.11%)						
	true KK	true NORMAL	class precision			
pred. KK	59	38	60.82%			
pred. NORMAL	6	98	94.23%			
class recall	90.77%	72.06%				
MLP		Coiflets 5 Aproximação 4				
accuracy: 90.52% +/- 5.24% (mikro: 90.55%)						
	true KK	true NORMAL	class precision			
pred. KK	54	8	87.10%			
pred. NORMAL	11	128	92.09%			
class recall	83.08%	94.12%				
RBF		Coiflets 5 Aproximação 4				
accuracy: 84.07% +/- 7.01% (mikro: 84.08%)						
	true KK	true NORMAL	class precision			
pred. KK	49	16	75.38%			
pred. NORMAL	16	120	88.24%			
class recall	75.38%	88.24%				
MLP		Coiflets 5 Aproximação 5				
accuracy: 89.07% +/- 7.65% (mikro: 89.05%)						
	true KK	true NORMAL	class precision			
pred. KK	54	11	83.08%			
pred. NORMAL	11	125	91.91%			
class recall	83.08%	91.91%				
RBF		Coiflets 5 Aproximação 5				
accuracy: 82.07% +/- 6.44% (mikro: 82.09%)						
	true KK	true NORMAL	class precision			
pred. KK	52	23	69.33%			
pred. NORMAL	13	113	89.68%			
class recall	80.00%	83.09%				
MLP		Daubechies 5 Aproximação 1				
accuracy: 92.52% +/- 6.43% (mikro: 92.54%)						
	true KK	true NORMAL	class precision			
pred. KK	55	5	91.67%			
pred. NORMAL	10	131	92.91%			
class recall	84.62%	96.32%				
RBF		Daubechies 5 Aproximação 1				
accuracy: 87.57% +/- 5.56% (mikro: 87.56%)						
	true KK	true NORMAL	class precision			
pred. KK	60	20	75.00%			
pred. NORMAL	5	116	95.87%			
class recall	92.31%	85.29%				
MLP		Daubechies 5 Aproximação 2				

accuracy: 89.05% +/- 6.25% (mikro: 89.05%)			
	true KK	true NORMAL	class precision
pred. KK	52	9	85.25%
pred. NORMAL	13	127	90.71%
class recall	80.00%	93.38%	
RBF	Daubechies 5 Aproximação 2		
accuracy: 86.57% +/- 5.48% (mikro: 86.57%)			
	true KK	true NORMAL	class precision
pred. KK	60	22	73.17%
pred. NORMAL	5	114	95.80%
class recall	92.31%	83.82%	
MLP	Daubechies 5 Aproximação 3		
accuracy: 90.07% +/- 7.02% (mikro: 90.05%)			
	true KK	true NORMAL	class precision
pred. KK	55	10	84.62%
pred. NORMAL	10	126	92.65%
class recall	84.62%	92.65%	
RBF	Daubechies 5 Aproximação 3		
accuracy: 85.07% +/- 5.48% (mikro: 85.07%)			
	true KK	true NORMAL	class precision
pred. KK	60	25	70.59%
pred. NORMAL	5	111	95.69%
class recall	92.31%	81.62%	
MLP	Daubechies 5 Aproximação 4		
accuracy: 90.57% +/- 6.44% (mikro: 90.55%)			
	true KK	true NORMAL	class precision
pred. KK	55	9	85.94%
pred. NORMAL	10	127	92.70%
class recall	84.62%	93.38%	
RBF	Daubechies 5 Aproximação 4		
accuracy: 82.10% +/- 5.07% (mikro: 82.09%)			
	true KK	true NORMAL	class precision
pred. KK	60	31	65.93%
pred. NORMAL	5	105	95.45%
class recall	92.31%	77.21%	
MLP	Daubechies 5 Aproximação 5		
accuracy: 89.07% +/- 6.59% (mikro: 89.05%)			
	true KK	true NORMAL	class precision
pred. KK	54	11	83.08%
pred. NORMAL	11	125	91.91%
class recall	83.08%	91.91%	
RBF	Daubechies 5 Aproximação 5		
accuracy: 82.10% +/- 5.54% (mikro: 82.09%)			
	true KK	true NORMAL	class precision
pred. KK	60	31	65.93%
pred. NORMAL	5	105	95.45%
class recall	92.31%	77.21%	
MLP	Daubechies 10 Aproximação 1		
accuracy: 90.55% +/- 5.22% (mikro: 90.55%)			
	true KK	true NORMAL	class precision
pred. KK	53	7	88.33%
pred. NORMAL	12	129	91.49%
class recall	81.54%	94.85%	
RBF	Daubechies 10 Aproximação 1		
accuracy: 88.07% +/- 5.97% (mikro: 88.06%)			
	true KK	true NORMAL	class precision
pred. KK	61	20	75.31%
pred. NORMAL	4	116	96.67%
class recall	93.85%	85.29%	
MLP	Daubechies 10 Aproximação 2		
accuracy: 91.02% +/- 6.65% (mikro: 91.04%)			
	true KK	true NORMAL	class precision
pred. KK	55	8	87.30%
pred. NORMAL	10	128	92.75%
class recall	84.62%	94.12%	
RBF	Daubechies 10 Aproximação 2		
accuracy: 85.57% +/- 6.10% (mikro: 85.57%)			
	true KK	true NORMAL	class precision
pred. KK	60	24	71.43%
pred. NORMAL	5	112	95.73%
class recall	92.31%	82.35%	

		MLP	Daubechies 10 Aproximação 3
		accuracy: 92.52% +/- 6.03% (mikro: 92.54%)	
		pred. KK	89.06%
		pred. NORMAL	94.16%
		class recall	94.85%
		RBF	Daubechies 10 Aproximação 3
		accuracy: 81.60% +/- 5.92% (mikro: 81.59%)	
		pred. KK	65.56%
		pred. NORMAL	94.59%
		class recall	77.21%
		MLP	Daubechies 10 Aproximação 4
		accuracy: 90.05% +/- 5.92% (mikro: 90.05%)	
		pred. KK	86.89%
		pred. NORMAL	91.43%
		class recall	94.12%
		RBF	Daubechies 10 Aproximação 4
		accuracy: 77.64% +/- 4.93% (mikro: 77.61%)	
		pred. KK	60.20%
		pred. NORMAL	94.17%
		class recall	71.32%
		MLP	Daubechies 10 Aproximação 5
		accuracy: 87.57% +/- 5.99% (mikro: 87.56%)	
		pred. KK	83.33%
		pred. NORMAL	89.36%
		class recall	92.65%
		RBF	Daubechies 10 Aproximação 5
		accuracy: 76.17% +/- 6.37% (mikro: 76.12%)	
		pred. KK	58.42%
		pred. NORMAL	94.00%
		class recall	69.12%
9	Dois pontos presentes 2 pontos ausentes picos da aplanção	MLP	Não houve
		accuracy: 90.05% +/- 5.92% (mikro: 90.05%)	
		pred. KK	85.71%
		pred. NORMAL	92.03%
		class recall	93.38%
		Árvore de decisão	Não houve
		accuracy: 86.07% +/- 7.34% (mikro: 86.07%)	
		pred. KK	79.37%
		pred. NORMAL	89.13%
		class recall	90.44%
		RBF	Não houve
		accuracy: 88.55% +/- 6.74% (mikro: 88.56%)	
		pred. KK	85.00%
		pred. NORMAL	90.07%
		class recall	93.38%
10	Os 10 pontos antes e os 10 depois do Pico 1 da Aplanção	MLP	Não houve
		accuracy: 85.02% +/- 8.09% (mikro: 85.07%)	
		pred. KK	78.92%
		pred. NORMAL	88.97%
		class recall	88.97%
		Árvore de decisão	Não houve
		accuracy: 86.02% +/- 7.71% (mikro: 86.07%)	
		pred. KK	77.61%
		pred. NORMAL	90.30%
		class recall	88.97%
		RBF	Não houve

		<table border="1"> <thead> <tr> <th colspan="4">accuracy: 81.05% +/- 6.31% (mikro: 81.09%)</th> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> </thead> <tbody> <tr> <td>pred. KK</td> <td>40</td> <td>13</td> <td>75.47%</td> </tr> <tr> <td>pred. NORMAL</td> <td>25</td> <td>123</td> <td>83.11%</td> </tr> <tr> <td>class recall</td> <td>61.54%</td> <td>90.44%</td> <td></td> </tr> </tbody> </table>	accuracy: 81.05% +/- 6.31% (mikro: 81.09%)					true KK	true NORMAL	class precision	pred. KK	40	13	75.47%	pred. NORMAL	25	123	83.11%	class recall	61.54%	90.44%			
accuracy: 81.05% +/- 6.31% (mikro: 81.09%)																								
	true KK	true NORMAL	class precision																					
pred. KK	40	13	75.47%																					
pred. NORMAL	25	123	83.11%																					
class recall	61.54%	90.44%																						
11	Os 25 pontos antes e os 25 depois do Pico 1 da Aplanção	<table border="1"> <thead> <tr> <th colspan="4">accuracy: 88.00% +/- 8.72% (mikro: 88.06%)</th> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> </thead> <tbody> <tr> <td>pred. KK</td> <td>52</td> <td>11</td> <td>82.54%</td> </tr> <tr> <td>pred. NORMAL</td> <td>13</td> <td>125</td> <td>90.58%</td> </tr> <tr> <td>class recall</td> <td>80.00%</td> <td>91.91%</td> <td></td> </tr> </tbody> </table>	accuracy: 88.00% +/- 8.72% (mikro: 88.06%)					true KK	true NORMAL	class precision	pred. KK	52	11	82.54%	pred. NORMAL	13	125	90.58%	class recall	80.00%	91.91%		MLP	Não houve
		accuracy: 88.00% +/- 8.72% (mikro: 88.06%)																						
			true KK	true NORMAL	class precision																			
		pred. KK	52	11	82.54%																			
pred. NORMAL	13	125	90.58%																					
class recall	80.00%	91.91%																						
<table border="1"> <thead> <tr> <th colspan="4">accuracy: 84.02% +/- 8.34% (mikro: 84.08%)</th> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> </thead> <tbody> <tr> <td>pred. KK</td> <td>52</td> <td>19</td> <td>73.24%</td> </tr> <tr> <td>pred. NORMAL</td> <td>13</td> <td>117</td> <td>90.00%</td> </tr> <tr> <td>class recall</td> <td>80.00%</td> <td>86.03%</td> <td></td> </tr> </tbody> </table>	accuracy: 84.02% +/- 8.34% (mikro: 84.08%)					true KK	true NORMAL	class precision	pred. KK	52	19	73.24%	pred. NORMAL	13	117	90.00%	class recall	80.00%	86.03%		Árvore de decisão	Não houve		
accuracy: 84.02% +/- 8.34% (mikro: 84.08%)																								
	true KK	true NORMAL	class precision																					
pred. KK	52	19	73.24%																					
pred. NORMAL	13	117	90.00%																					
class recall	80.00%	86.03%																						
<table border="1"> <thead> <tr> <th colspan="4">accuracy: 83.05% +/- 6.83% (mikro: 83.08%)</th> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> </thead> <tbody> <tr> <td>pred. KK</td> <td>52</td> <td>21</td> <td>71.23%</td> </tr> <tr> <td>pred. NORMAL</td> <td>13</td> <td>115</td> <td>89.84%</td> </tr> <tr> <td>class recall</td> <td>80.00%</td> <td>84.56%</td> <td></td> </tr> </tbody> </table>	accuracy: 83.05% +/- 6.83% (mikro: 83.08%)					true KK	true NORMAL	class precision	pred. KK	52	21	71.23%	pred. NORMAL	13	115	89.84%	class recall	80.00%	84.56%		RBF	Não houve		
accuracy: 83.05% +/- 6.83% (mikro: 83.08%)																								
	true KK	true NORMAL	class precision																					
pred. KK	52	21	71.23%																					
pred. NORMAL	13	115	89.84%																					
class recall	80.00%	84.56%																						
12	Os 50 pontos antes e os 50 depois do Pico 1 da Aplanção	<table border="1"> <thead> <tr> <th colspan="4">accuracy: 84.52% +/- 9.37% (mikro: 84.58%)</th> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> </thead> <tbody> <tr> <td>pred. KK</td> <td>48</td> <td>14</td> <td>77.42%</td> </tr> <tr> <td>pred. NORMAL</td> <td>17</td> <td>122</td> <td>87.77%</td> </tr> <tr> <td>class recall</td> <td>73.85%</td> <td>89.71%</td> <td></td> </tr> </tbody> </table>	accuracy: 84.52% +/- 9.37% (mikro: 84.58%)					true KK	true NORMAL	class precision	pred. KK	48	14	77.42%	pred. NORMAL	17	122	87.77%	class recall	73.85%	89.71%		MLP	Não houve
		accuracy: 84.52% +/- 9.37% (mikro: 84.58%)																						
			true KK	true NORMAL	class precision																			
		pred. KK	48	14	77.42%																			
pred. NORMAL	17	122	87.77%																					
class recall	73.85%	89.71%																						
<table border="1"> <thead> <tr> <th colspan="4">accuracy: 84.57% +/- 6.51% (mikro: 84.58%)</th> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> </thead> <tbody> <tr> <td>pred. KK</td> <td>48</td> <td>14</td> <td>77.42%</td> </tr> <tr> <td>pred. NORMAL</td> <td>17</td> <td>122</td> <td>87.77%</td> </tr> <tr> <td>class recall</td> <td>73.85%</td> <td>89.71%</td> <td></td> </tr> </tbody> </table>	accuracy: 84.57% +/- 6.51% (mikro: 84.58%)					true KK	true NORMAL	class precision	pred. KK	48	14	77.42%	pred. NORMAL	17	122	87.77%	class recall	73.85%	89.71%		Árvore de decisão	Não houve		
accuracy: 84.57% +/- 6.51% (mikro: 84.58%)																								
	true KK	true NORMAL	class precision																					
pred. KK	48	14	77.42%																					
pred. NORMAL	17	122	87.77%																					
class recall	73.85%	89.71%																						
<table border="1"> <thead> <tr> <th colspan="4">accuracy: 86.55% +/- 4.54% (mikro: 86.57%)</th> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> </thead> <tbody> <tr> <td>pred. KK</td> <td>42</td> <td>4</td> <td>91.30%</td> </tr> <tr> <td>pred. NORMAL</td> <td>23</td> <td>132</td> <td>85.16%</td> </tr> <tr> <td>class recall</td> <td>64.62%</td> <td>97.06%</td> <td></td> </tr> </tbody> </table>	accuracy: 86.55% +/- 4.54% (mikro: 86.57%)					true KK	true NORMAL	class precision	pred. KK	42	4	91.30%	pred. NORMAL	23	132	85.16%	class recall	64.62%	97.06%		RBF	Não houve		
accuracy: 86.55% +/- 4.54% (mikro: 86.57%)																								
	true KK	true NORMAL	class precision																					
pred. KK	42	4	91.30%																					
pred. NORMAL	23	132	85.16%																					
class recall	64.62%	97.06%																						
13	Os 10 pontos antes e os 10 depois do Pico 2 da Aplanção	<table border="1"> <thead> <tr> <th colspan="4">accuracy: 84.60% +/- 6.82% (mikro: 84.58%)</th> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> </thead> <tbody> <tr> <td>pred. KK</td> <td>47</td> <td>13</td> <td>78.33%</td> </tr> <tr> <td>pred. NORMAL</td> <td>18</td> <td>123</td> <td>87.23%</td> </tr> <tr> <td>class recall</td> <td>72.31%</td> <td>90.44%</td> <td></td> </tr> </tbody> </table>	accuracy: 84.60% +/- 6.82% (mikro: 84.58%)					true KK	true NORMAL	class precision	pred. KK	47	13	78.33%	pred. NORMAL	18	123	87.23%	class recall	72.31%	90.44%		MLP	Não houve
		accuracy: 84.60% +/- 6.82% (mikro: 84.58%)																						
			true KK	true NORMAL	class precision																			
		pred. KK	47	13	78.33%																			
pred. NORMAL	18	123	87.23%																					
class recall	72.31%	90.44%																						
<table border="1"> <thead> <tr> <th colspan="4">accuracy: 82.60% +/- 6.77% (mikro: 82.59%)</th> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> </thead> <tbody> <tr> <td>pred. KK</td> <td>51</td> <td>21</td> <td>70.83%</td> </tr> <tr> <td>pred. NORMAL</td> <td>14</td> <td>115</td> <td>89.15%</td> </tr> <tr> <td>class recall</td> <td>78.46%</td> <td>84.56%</td> <td></td> </tr> </tbody> </table>	accuracy: 82.60% +/- 6.77% (mikro: 82.59%)					true KK	true NORMAL	class precision	pred. KK	51	21	70.83%	pred. NORMAL	14	115	89.15%	class recall	78.46%	84.56%		Árvore de decisão	Não houve		
accuracy: 82.60% +/- 6.77% (mikro: 82.59%)																								
	true KK	true NORMAL	class precision																					
pred. KK	51	21	70.83%																					
pred. NORMAL	14	115	89.15%																					
class recall	78.46%	84.56%																						
<table border="1"> <thead> <tr> <th colspan="4">accuracy: 84.57% +/- 5.23% (mikro: 84.58%)</th> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> </thead> <tbody> <tr> <td>pred. KK</td> <td>48</td> <td>14</td> <td>77.42%</td> </tr> <tr> <td>pred. NORMAL</td> <td>17</td> <td>122</td> <td>87.77%</td> </tr> <tr> <td>class recall</td> <td>73.85%</td> <td>89.71%</td> <td></td> </tr> </tbody> </table>	accuracy: 84.57% +/- 5.23% (mikro: 84.58%)					true KK	true NORMAL	class precision	pred. KK	48	14	77.42%	pred. NORMAL	17	122	87.77%	class recall	73.85%	89.71%		RBF	Não houve		
accuracy: 84.57% +/- 5.23% (mikro: 84.58%)																								
	true KK	true NORMAL	class precision																					
pred. KK	48	14	77.42%																					
pred. NORMAL	17	122	87.77%																					
class recall	73.85%	89.71%																						
14	Os 25 pontos antes e os 25 depois do Pico 2 da Aplanção	<table border="1"> <thead> <tr> <th colspan="4">accuracy: 88.05% +/- 5.12% (mikro: 88.06%)</th> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> </thead> <tbody> <tr> <td>pred. KK</td> <td>52</td> <td>11</td> <td>82.54%</td> </tr> <tr> <td>pred. NORMAL</td> <td>13</td> <td>125</td> <td>90.58%</td> </tr> <tr> <td>class recall</td> <td>80.00%</td> <td>91.91%</td> <td></td> </tr> </tbody> </table>	accuracy: 88.05% +/- 5.12% (mikro: 88.06%)					true KK	true NORMAL	class precision	pred. KK	52	11	82.54%	pred. NORMAL	13	125	90.58%	class recall	80.00%	91.91%		MLP	Não houve
		accuracy: 88.05% +/- 5.12% (mikro: 88.06%)																						
	true KK	true NORMAL	class precision																					
pred. KK	52	11	82.54%																					
pred. NORMAL	13	125	90.58%																					
class recall	80.00%	91.91%																						
Árvore de decisão	Não houve																							

		<table border="1"> <thead> <tr> <th colspan="4">accuracy: 86.05% +/- 6.28% (mikro: 86.07%)</th> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> </thead> <tbody> <tr> <td>pred. KK</td> <td>53</td> <td>16</td> <td>76.81%</td> </tr> <tr> <td>pred. NORMAL</td> <td>12</td> <td>120</td> <td>90.91%</td> </tr> <tr> <td>class recall</td> <td>81.54%</td> <td>88.24%</td> <td></td> </tr> </tbody> </table>	accuracy: 86.05% +/- 6.28% (mikro: 86.07%)					true KK	true NORMAL	class precision	pred. KK	53	16	76.81%	pred. NORMAL	12	120	90.91%	class recall	81.54%	88.24%			
accuracy: 86.05% +/- 6.28% (mikro: 86.07%)																								
	true KK	true NORMAL	class precision																					
pred. KK	53	16	76.81%																					
pred. NORMAL	12	120	90.91%																					
class recall	81.54%	88.24%																						
		<table border="1"> <thead> <tr> <th colspan="2">RBF</th> <th>Não houve</th> </tr> </thead> <tbody> <tr> <td colspan="3">accuracy: 87.55% +/- 5.15% (mikro: 87.56%)</td> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> <tr> <td>pred. KK</td> <td>49</td> <td>9</td> <td>84.48%</td> </tr> <tr> <td>pred. NORMAL</td> <td>16</td> <td>127</td> <td>88.81%</td> </tr> <tr> <td>class recall</td> <td>75.38%</td> <td>93.38%</td> <td></td> </tr> </tbody> </table>	RBF		Não houve	accuracy: 87.55% +/- 5.15% (mikro: 87.56%)				true KK	true NORMAL	class precision	pred. KK	49	9	84.48%	pred. NORMAL	16	127	88.81%	class recall	75.38%	93.38%	
RBF		Não houve																						
accuracy: 87.55% +/- 5.15% (mikro: 87.56%)																								
	true KK	true NORMAL	class precision																					
pred. KK	49	9	84.48%																					
pred. NORMAL	16	127	88.81%																					
class recall	75.38%	93.38%																						
15	Os 50 pontos antes e os 50 depois do Pico 2 da Aplanção	<table border="1"> <thead> <tr> <th colspan="2">MLP</th> <th>Não houve</th> </tr> </thead> <tbody> <tr> <td colspan="3">accuracy: 85.57% +/- 6.87% (mikro: 85.57%)</td> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> <tr> <td>pred. KK</td> <td>48</td> <td>12</td> <td>80.00%</td> </tr> <tr> <td>pred. NORMAL</td> <td>17</td> <td>124</td> <td>87.94%</td> </tr> <tr> <td>class recall</td> <td>73.85%</td> <td>91.18%</td> <td></td> </tr> </tbody> </table>	MLP		Não houve	accuracy: 85.57% +/- 6.87% (mikro: 85.57%)				true KK	true NORMAL	class precision	pred. KK	48	12	80.00%	pred. NORMAL	17	124	87.94%	class recall	73.85%	91.18%	
MLP		Não houve																						
accuracy: 85.57% +/- 6.87% (mikro: 85.57%)																								
	true KK	true NORMAL	class precision																					
pred. KK	48	12	80.00%																					
pred. NORMAL	17	124	87.94%																					
class recall	73.85%	91.18%																						
		<table border="1"> <thead> <tr> <th colspan="2">Árvore de decisão</th> <th>Não houve</th> </tr> </thead> <tbody> <tr> <td colspan="3">accuracy: 82.07% +/- 8.15% (mikro: 82.09%)</td> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> <tr> <td>pred. KK</td> <td>46</td> <td>17</td> <td>73.02%</td> </tr> <tr> <td>pred. NORMAL</td> <td>19</td> <td>119</td> <td>86.23%</td> </tr> <tr> <td>class recall</td> <td>70.77%</td> <td>87.50%</td> <td></td> </tr> </tbody> </table>	Árvore de decisão		Não houve	accuracy: 82.07% +/- 8.15% (mikro: 82.09%)				true KK	true NORMAL	class precision	pred. KK	46	17	73.02%	pred. NORMAL	19	119	86.23%	class recall	70.77%	87.50%	
Árvore de decisão		Não houve																						
accuracy: 82.07% +/- 8.15% (mikro: 82.09%)																								
	true KK	true NORMAL	class precision																					
pred. KK	46	17	73.02%																					
pred. NORMAL	19	119	86.23%																					
class recall	70.77%	87.50%																						
		<table border="1"> <thead> <tr> <th colspan="2">RBF</th> <th>Não houve</th> </tr> </thead> <tbody> <tr> <td colspan="3">accuracy: 87.55% +/- 7.52% (mikro: 87.56%)</td> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> <tr> <td>pred. KK</td> <td>48</td> <td>8</td> <td>85.71%</td> </tr> <tr> <td>pred. NORMAL</td> <td>17</td> <td>128</td> <td>88.28%</td> </tr> <tr> <td>class recall</td> <td>73.85%</td> <td>94.12%</td> <td></td> </tr> </tbody> </table>	RBF		Não houve	accuracy: 87.55% +/- 7.52% (mikro: 87.56%)				true KK	true NORMAL	class precision	pred. KK	48	8	85.71%	pred. NORMAL	17	128	88.28%	class recall	73.85%	94.12%	
RBF		Não houve																						
accuracy: 87.55% +/- 7.52% (mikro: 87.56%)																								
	true KK	true NORMAL	class precision																					
pred. KK	48	8	85.71%																					
pred. NORMAL	17	128	88.28%																					
class recall	73.85%	94.12%																						
16	Todos os pontos Aplanção e Todos Pressão	<table border="1"> <thead> <tr> <th colspan="2">RBF</th> <th>Não houve</th> </tr> </thead> <tbody> <tr> <td colspan="3">accuracy: 90.55% +/- 5.68% (mikro: 90.55%)</td> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> <tr> <td>pred. KK</td> <td>52</td> <td>6</td> <td>89.66%</td> </tr> <tr> <td>pred. NORMAL</td> <td>13</td> <td>130</td> <td>90.91%</td> </tr> <tr> <td>class recall</td> <td>80.00%</td> <td>95.59%</td> <td></td> </tr> </tbody> </table>	RBF		Não houve	accuracy: 90.55% +/- 5.68% (mikro: 90.55%)				true KK	true NORMAL	class precision	pred. KK	52	6	89.66%	pred. NORMAL	13	130	90.91%	class recall	80.00%	95.59%	
RBF		Não houve																						
accuracy: 90.55% +/- 5.68% (mikro: 90.55%)																								
	true KK	true NORMAL	class precision																					
pred. KK	52	6	89.66%																					
pred. NORMAL	13	130	90.91%																					
class recall	80.00%	95.59%																						
17	Os 50 pontos antes e os 50 depois dos dois picos da Aplanção junto com os valores da pressão das mesmas posições	<table border="1"> <thead> <tr> <th colspan="2">MLP</th> <th>Não houve</th> </tr> </thead> <tbody> <tr> <td colspan="3">accuracy: 91.02% +/- 6.65% (mikro: 91.04%)</td> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> <tr> <td>pred. KK</td> <td>55</td> <td>8</td> <td>87.30%</td> </tr> <tr> <td>pred. NORMAL</td> <td>10</td> <td>128</td> <td>92.75%</td> </tr> <tr> <td>class recall</td> <td>84.62%</td> <td>94.12%</td> <td></td> </tr> </tbody> </table>	MLP		Não houve	accuracy: 91.02% +/- 6.65% (mikro: 91.04%)				true KK	true NORMAL	class precision	pred. KK	55	8	87.30%	pred. NORMAL	10	128	92.75%	class recall	84.62%	94.12%	
MLP		Não houve																						
accuracy: 91.02% +/- 6.65% (mikro: 91.04%)																								
	true KK	true NORMAL	class precision																					
pred. KK	55	8	87.30%																					
pred. NORMAL	10	128	92.75%																					
class recall	84.62%	94.12%																						
		<table border="1"> <thead> <tr> <th colspan="2">Árvore de decisão</th> <th>Não houve</th> </tr> </thead> <tbody> <tr> <td colspan="3">accuracy: 84.05% +/- 7.39% (mikro: 84.08%)</td> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> <tr> <td>pred. KK</td> <td>48</td> <td>15</td> <td>76.19%</td> </tr> <tr> <td>pred. NORMAL</td> <td>17</td> <td>121</td> <td>87.68%</td> </tr> <tr> <td>class recall</td> <td>73.85%</td> <td>88.97%</td> <td></td> </tr> </tbody> </table>	Árvore de decisão		Não houve	accuracy: 84.05% +/- 7.39% (mikro: 84.08%)				true KK	true NORMAL	class precision	pred. KK	48	15	76.19%	pred. NORMAL	17	121	87.68%	class recall	73.85%	88.97%	
Árvore de decisão		Não houve																						
accuracy: 84.05% +/- 7.39% (mikro: 84.08%)																								
	true KK	true NORMAL	class precision																					
pred. KK	48	15	76.19%																					
pred. NORMAL	17	121	87.68%																					
class recall	73.85%	88.97%																						
		<table border="1"> <thead> <tr> <th colspan="2">RBF</th> <th>Não houve</th> </tr> </thead> <tbody> <tr> <td colspan="3">accuracy: 89.50% +/- 8.20% (mikro: 89.55%)</td> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> <tr> <td>pred. KK</td> <td>50</td> <td>6</td> <td>89.29%</td> </tr> <tr> <td>pred. NORMAL</td> <td>15</td> <td>130</td> <td>89.66%</td> </tr> <tr> <td>class recall</td> <td>76.92%</td> <td>95.59%</td> <td></td> </tr> </tbody> </table>	RBF		Não houve	accuracy: 89.50% +/- 8.20% (mikro: 89.55%)				true KK	true NORMAL	class precision	pred. KK	50	6	89.29%	pred. NORMAL	15	130	89.66%	class recall	76.92%	95.59%	
RBF		Não houve																						
accuracy: 89.50% +/- 8.20% (mikro: 89.55%)																								
	true KK	true NORMAL	class precision																					
pred. KK	50	6	89.29%																					
pred. NORMAL	15	130	89.66%																					
class recall	76.92%	95.59%																						
		<table border="1"> <thead> <tr> <th colspan="2">MLP</th> <th>Haar Aproximação 3</th> </tr> </thead> <tbody> <tr> <td colspan="3">accuracy: 93.00% +/- 4.58% (mikro: 93.03%)</td> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> <tr> <td>pred. KK</td> <td>57</td> <td>6</td> <td>90.48%</td> </tr> <tr> <td>pred. NORMAL</td> <td>8</td> <td>130</td> <td>94.20%</td> </tr> <tr> <td>class recall</td> <td>87.69%</td> <td>95.59%</td> <td></td> </tr> </tbody> </table>	MLP		Haar Aproximação 3	accuracy: 93.00% +/- 4.58% (mikro: 93.03%)				true KK	true NORMAL	class precision	pred. KK	57	6	90.48%	pred. NORMAL	8	130	94.20%	class recall	87.69%	95.59%	
MLP		Haar Aproximação 3																						
accuracy: 93.00% +/- 4.58% (mikro: 93.03%)																								
	true KK	true NORMAL	class precision																					
pred. KK	57	6	90.48%																					
pred. NORMAL	8	130	94.20%																					
class recall	87.69%	95.59%																						
		<table border="1"> <thead> <tr> <th colspan="2">RBF</th> <th>Haar Aproximação 3</th> </tr> </thead> <tbody> <tr> <td colspan="3">accuracy: 86.07% +/- 6.99% (mikro: 86.07%)</td> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> <tr> <td>pred. KK</td> <td>59</td> <td>22</td> <td>72.84%</td> </tr> <tr> <td>pred. NORMAL</td> <td>6</td> <td>114</td> <td>95.00%</td> </tr> <tr> <td>class recall</td> <td>90.77%</td> <td>83.82%</td> <td></td> </tr> </tbody> </table>	RBF		Haar Aproximação 3	accuracy: 86.07% +/- 6.99% (mikro: 86.07%)				true KK	true NORMAL	class precision	pred. KK	59	22	72.84%	pred. NORMAL	6	114	95.00%	class recall	90.77%	83.82%	
RBF		Haar Aproximação 3																						
accuracy: 86.07% +/- 6.99% (mikro: 86.07%)																								
	true KK	true NORMAL	class precision																					
pred. KK	59	22	72.84%																					
pred. NORMAL	6	114	95.00%																					
class recall	90.77%	83.82%																						
		<table border="1"> <thead> <tr> <th colspan="2">MLP</th> <th>Coiflets 1 Aproximação 3</th> </tr> </thead> <tbody> <tr> <td colspan="3">accuracy: 91.00% +/- 5.83% (mikro: 91.04%)</td> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> <tr> <td>pred. KK</td> <td>54</td> <td>7</td> <td>88.52%</td> </tr> <tr> <td>pred. NORMAL</td> <td>11</td> <td>129</td> <td>92.14%</td> </tr> <tr> <td>class recall</td> <td>83.08%</td> <td>94.85%</td> <td></td> </tr> </tbody> </table>	MLP		Coiflets 1 Aproximação 3	accuracy: 91.00% +/- 5.83% (mikro: 91.04%)				true KK	true NORMAL	class precision	pred. KK	54	7	88.52%	pred. NORMAL	11	129	92.14%	class recall	83.08%	94.85%	
MLP		Coiflets 1 Aproximação 3																						
accuracy: 91.00% +/- 5.83% (mikro: 91.04%)																								
	true KK	true NORMAL	class precision																					
pred. KK	54	7	88.52%																					
pred. NORMAL	11	129	92.14%																					
class recall	83.08%	94.85%																						

		RBF	Coiflets 1 Aproximação 3		
		accuracy: 85.57% +/- 6.87% (mikro: 85.57%)			
			true KK	true NORMAL	class precision
		pred. KK	59	23	71.95%
		pred. NORMAL	6	113	94.96%
class recall	90.77%	83.09%			
		MLP	Coiflets 5 Aproximação 1		
		accuracy: 91.52% +/- 5.52% (mikro: 91.54%)			
			true KK	true NORMAL	class precision
		pred. KK	56	8	87.50%
		pred. NORMAL	9	128	93.43%
class recall	86.15%	94.12%			
		RBF	Coiflets 5 Aproximação 1		
		accuracy: 85.07% +/- 6.71% (mikro: 85.07%)			
			true KK	true NORMAL	class precision
		pred. KK	59	24	71.08%
		pred. NORMAL	6	112	94.92%
class recall	90.77%	82.35%			
		MLP	Daubechies 10 Aproximação 1		
		accuracy: 91.02% +/- 6.65% (mikro: 91.04%)			
			true KK	true NORMAL	class precision
		pred. KK	55	8	87.30%
		pred. NORMAL	10	128	92.75%
class recall	84.62%	94.12%			
		RBF	Daubechies 10 Aproximação 1		
		accuracy: 85.07% +/- 6.71% (mikro: 85.07%)			
			true KK	true NORMAL	class precision
		pred. KK	59	24	71.08%
		pred. NORMAL	6	112	94.92%
class recall	90.77%	82.35%			
18	Os 50 pontos antes e os 50 depois dos dois picos da Aplanção junto com o valor da primeira posição da pressão + o valor da pressão na posição do pico da aplanção + o valor da pressão na última posição da aplanção	MLP	Não houve		
		accuracy: 91.55% +/- 5.93% (mikro: 91.54%)			
			true KK	true NORMAL	class precision
		pred. KK	54	6	90.00%
		pred. NORMAL	11	130	92.20%
class recall	83.08%	95.59%			
		Árvore de decisão	Não houve		
		accuracy: 84.05% +/- 7.39% (mikro: 84.08%)			
			true KK	true NORMAL	class precision
		pred. KK	48	15	76.19%
		pred. NORMAL	17	121	87.68%
class recall	73.85%	88.97%			
		RBF	Não houve		
		accuracy: 85.55% +/- 6.14% (mikro: 85.57%)			
			true KK	true NORMAL	class precision
		pred. KK	44	8	84.62%
		pred. NORMAL	21	128	85.91%
class recall	67.69%	94.12%			
19	Os 50 pontos antes e os 50 depois do Pico 1 da Aplanção junto com os valores da pressão das mesmas posições	MLP	Não houve		
		accuracy: 89.00% +/- 7.68% (mikro: 89.05%)			
			true KK	true NORMAL	class precision
		pred. KK	52	9	85.25%
		pred. NORMAL	13	127	90.71%
class recall	80.00%	93.38%			
		Árvore de decisão	Não houve		
		accuracy: 85.55% +/- 6.91% (mikro: 85.57%)			
			true KK	true NORMAL	class precision
		pred. KK	47	11	81.03%
		pred. NORMAL	18	125	87.41%
class recall	72.31%	91.91%			
		RBF	Não houve		

		accuracy: 88.02% +/- 6.03% (mikro: 88.06%)		
		pred. KK	51	10
		pred. NORMAL	14	126
		class recall	78.46%	92.65%
		true KK		class precision
				83.81%
				90.00%
20	Os 50 pontos antes e os 50 depois do Pico 1 da Aplanção junto com o valor da primeira posição da pressão + o valor da pressão na posição do pico da aplanção + o valor da pressão na última posição da aplanção	MLP	Não houve	
		accuracy: 86.50% +/- 8.38% (mikro: 86.57%)		
		pred. KK	48	10
		pred. NORMAL	17	126
		class recall	73.85%	92.65%
		true KK		class precision
				82.76%
				88.11%
		Árvore de decisão	Não houve	
		accuracy: 83.57% +/- 7.11% (mikro: 83.58%)		
		pred. KK	47	15
		pred. NORMAL	18	121
		class recall	72.31%	88.97%
		true KK		class precision
				75.81%
				87.05%
		RBF	Não houve	
		accuracy: 86.55% +/- 4.54% (mikro: 86.57%)		
		pred. KK	42	4
		pred. NORMAL	23	132
		class recall	64.62%	97.06%
		true KK		class precision
				91.30%
				85.18%
21	Os 50 pontos antes e os 50 depois do Pico 2 da Aplanção junto com os valores da pressão das mesmas posições	MLP	Não houve	
		accuracy: 92.05% +/- 3.98% (mikro: 92.04%)		
		pred. KK	56	7
		pred. NORMAL	9	129
		class recall	86.15%	94.85%
		true KK		class precision
				88.89%
				93.48%
		Árvore de decisão	Não houve	
		accuracy: 82.07% +/- 8.15% (mikro: 82.09%)		
		pred. KK	46	17
		pred. NORMAL	19	119
		class recall	70.77%	87.50%
		true KK		class precision
				73.02%
				86.23%
		RBF	Não houve	
		accuracy: 89.05% +/- 5.40% (mikro: 89.05%)		
		pred. KK	51	8
		pred. NORMAL	14	128
		class recall	78.46%	94.12%
		true KK		class precision
				86.44%
				90.14%
22	Os 50 pontos antes e os 50 depois do Pico 2 da Aplanção junto com o valor da primeira posição da pressão + o valor da pressão na posição do pico da aplanção + o valor da pressão na última posição da aplanção	MLP	Não houve	
		accuracy: 89.05% +/- 5.40% (mikro: 89.05%)		
		pred. KK	51	8
		pred. NORMAL	14	128
		class recall	78.46%	94.12%
		true KK		class precision
				86.44%
				90.14%
		Árvore de decisão	Não houve	
		accuracy: 82.07% +/- 8.15% (mikro: 82.09%)		
		pred. KK	46	17
		pred. NORMAL	19	119
		class recall	70.77%	87.50%
		true KK		class precision
				73.02%
				86.23%
		RBF	Não houve	
		accuracy: 88.55% +/- 7.10% (mikro: 88.56%)		
		pred. KK	49	7
		pred. NORMAL	16	129
		class recall	75.38%	94.85%
		true KK		class precision
				87.50%
				88.97%

23	Os 50 pontos antes e os 50 depois dos Picos da Aplanção junto com a posição do pico da pressão + posição do pico 1 + posição do pico 2 + valor do pico da pressão	MLP	Não houve																				
		<table border="1"> <thead> <tr> <th colspan="4">accuracy: 90.52% +/- 6.52% (mikro: 90.55%)</th> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> </thead> <tbody> <tr> <td>pred. KK</td> <td>54</td> <td>8</td> <td>87.10%</td> </tr> <tr> <td>pred. NORMAL</td> <td>11</td> <td>128</td> <td>92.09%</td> </tr> <tr> <td>class recall</td> <td>83.08%</td> <td>94.12%</td> <td></td> </tr> </tbody> </table>		accuracy: 90.52% +/- 6.52% (mikro: 90.55%)					true KK	true NORMAL	class precision	pred. KK	54	8	87.10%	pred. NORMAL	11	128	92.09%	class recall	83.08%	94.12%	
		accuracy: 90.52% +/- 6.52% (mikro: 90.55%)																					
	true KK	true NORMAL	class precision																				
pred. KK	54	8	87.10%																				
pred. NORMAL	11	128	92.09%																				
class recall	83.08%	94.12%																					
Árvore de decisão	Não houve																						
24	O valor das posições: -50, -25, o pico, 25 e 50 antes e depois dos Picos da Aplanção junto com a posição do pico da pressão + posição do pico 1 + posição do pico 2 + valor do pico da pressão	MLP	Não houve																				
		<table border="1"> <thead> <tr> <th colspan="4">accuracy: 89.00% +/- 7.00% (mikro: 89.05%)</th> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> </thead> <tbody> <tr> <td>pred. KK</td> <td>52</td> <td>9</td> <td>85.25%</td> </tr> <tr> <td>pred. NORMAL</td> <td>13</td> <td>127</td> <td>90.71%</td> </tr> <tr> <td>class recall</td> <td>80.00%</td> <td>93.38%</td> <td></td> </tr> </tbody> </table>		accuracy: 89.00% +/- 7.00% (mikro: 89.05%)					true KK	true NORMAL	class precision	pred. KK	52	9	85.25%	pred. NORMAL	13	127	90.71%	class recall	80.00%	93.38%	
		accuracy: 89.00% +/- 7.00% (mikro: 89.05%)																					
	true KK	true NORMAL	class precision																				
pred. KK	52	9	85.25%																				
pred. NORMAL	13	127	90.71%																				
class recall	80.00%	93.38%																					
Árvore de decisão	Não houve																						
25	Convolução dos 50 pontos antes e depois dos picos da aplanção com os pontos da pressão dos mesmos momentos	MLP	Não houve																				
		<table border="1"> <thead> <tr> <th colspan="4">accuracy: 88.00% +/- 9.54% (mikro: 88.06%)</th> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> </thead> <tbody> <tr> <td>pred. KK</td> <td>50</td> <td>9</td> <td>84.75%</td> </tr> <tr> <td>pred. NORMAL</td> <td>15</td> <td>127</td> <td>89.44%</td> </tr> <tr> <td>class recall</td> <td>76.92%</td> <td>93.38%</td> <td></td> </tr> </tbody> </table>		accuracy: 88.00% +/- 9.54% (mikro: 88.06%)					true KK	true NORMAL	class precision	pred. KK	50	9	84.75%	pred. NORMAL	15	127	89.44%	class recall	76.92%	93.38%	
		accuracy: 88.00% +/- 9.54% (mikro: 88.06%)																					
	true KK	true NORMAL	class precision																				
pred. KK	50	9	84.75%																				
pred. NORMAL	15	127	89.44%																				
class recall	76.92%	93.38%																					
RBF	Não houve																						
25	Convolução dos 50 pontos antes e depois dos picos da aplanção com os pontos da pressão dos mesmos momentos	MLP	Haar Aproximação 3																				
		<table border="1"> <thead> <tr> <th colspan="4">accuracy: 91.00% +/- 6.24% (mikro: 91.04%)</th> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> </thead> <tbody> <tr> <td>pred. KK</td> <td>56</td> <td>9</td> <td>86.15%</td> </tr> <tr> <td>pred. NORMAL</td> <td>9</td> <td>127</td> <td>93.38%</td> </tr> <tr> <td>class recall</td> <td>86.15%</td> <td>93.38%</td> <td></td> </tr> </tbody> </table>		accuracy: 91.00% +/- 6.24% (mikro: 91.04%)					true KK	true NORMAL	class precision	pred. KK	56	9	86.15%	pred. NORMAL	9	127	93.38%	class recall	86.15%	93.38%	
		accuracy: 91.00% +/- 6.24% (mikro: 91.04%)																					
	true KK	true NORMAL	class precision																				
pred. KK	56	9	86.15%																				
pred. NORMAL	9	127	93.38%																				
class recall	86.15%	93.38%																					
RBF	Haar Aproximação 3																						
25	Convolução dos 50 pontos antes e depois dos picos da aplanção com os pontos da pressão dos mesmos momentos	MLP	Coiflets 1 Aproximação 3																				
		<table border="1"> <thead> <tr> <th colspan="4">accuracy: 91.00% +/- 5.39% (mikro: 91.04%)</th> </tr> <tr> <th></th> <th>true KK</th> <th>true NORMAL</th> <th>class precision</th> </tr> </thead> <tbody> <tr> <td>pred. KK</td> <td>57</td> <td>10</td> <td>85.07%</td> </tr> <tr> <td>pred. NORMAL</td> <td>8</td> <td>126</td> <td>94.03%</td> </tr> <tr> <td>class recall</td> <td>87.69%</td> <td>92.65%</td> <td></td> </tr> </tbody> </table>		accuracy: 91.00% +/- 5.39% (mikro: 91.04%)					true KK	true NORMAL	class precision	pred. KK	57	10	85.07%	pred. NORMAL	8	126	94.03%	class recall	87.69%	92.65%	
		accuracy: 91.00% +/- 5.39% (mikro: 91.04%)																					
	true KK	true NORMAL	class precision																				
pred. KK	57	10	85.07%																				
pred. NORMAL	8	126	94.03%																				
class recall	87.69%	92.65%																					
RBF	Coiflets 1 Aproximação 3																						

accuracy: 78.64% +/- 5.29% (mikro: 78.61%)			
	true KK	true NORMAL	class precision
pred. KK	61	39	61.00%
pred. NORMAL	4	97	96.04%
class recall	93.85%	71.32%	
MLP		Coiflets 5 Aproximação 1	
accuracy: 92.00% +/- 5.57% (mikro: 92.04%)			
	true KK	true NORMAL	class precision
pred. KK	58	9	86.57%
pred. NORMAL	7	127	94.78%
class recall	89.23%	93.38%	
RBF		Coiflets 5 Aproximação 1	
accuracy: 78.64% +/- 5.29% (mikro: 78.61%)			
	true KK	true NORMAL	class precision
pred. KK	61	39	61.00%
pred. NORMAL	4	97	96.04%
class recall	93.85%	71.32%	
MLP		Daubechies 10 Aproximação 1	
accuracy: 91.50% +/- 5.02% (mikro: 91.54%)			
	true KK	true NORMAL	class precision
pred. KK	57	9	86.36%
pred. NORMAL	8	127	94.07%
class recall	87.69%	93.38%	
RBF		Daubechies 10 Aproximação 1	
accuracy: 78.64% +/- 5.29% (mikro: 78.61%)			
	true KK	true NORMAL	class precision
pred. KK	61	39	61.00%
pred. NORMAL	4	97	96.04%
class recall	93.85%	71.32%	