

**UNIVERSIDADE FEDERAL DE SANTA CATARINA  
DEPARTAMENTO DE COMPUTAÇÃO**

Renan Cunha dos Santos

**IDENTIFICAÇÃO DE FALHAS ESTRUTURAIS EM  
TELHAS CERÂMICAS ATRAVÉS DA ANÁLISE DE  
EMIÇÃO ACÚSTICA**

Araranguá

2018



Renan Cunha dos Santos

**IDENTIFICAÇÃO DE FALHAS ESTRUTURAIS EM  
TELHAS CERÂMICAS ATRAVÉS DA ANÁLISE DE  
EMIÇÃO ACÚSTICA**

Monografia submetida à Engenharia  
de Computação para a obtenção do  
Grau de Bacharelado em Engenharia  
de Computação.

Orientador: Prof. Dr. Fabrício de Oli-  
veira Ourique

Araranguá

2018



Ficha de identificação da obra elaborada pelo autor,  
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

dos Santos, Renan Cunha

Identificação de falhas estruturais em telhas  
cerâmicas através da análise de emissão acústica /  
Renan Cunha dos Santos ; orientador, Fabrício de  
Oliveira Ourique, 2018.

101 p.

Trabalho de Conclusão de Curso (graduação) -  
Universidade Federal de Santa Catarina, Campus  
Araranguá, Graduação em Engenharia de Computação,  
Araranguá, 2018.

Inclui referências.

1. Engenharia de Computação. 2. Aprendizado de  
Máquina. 3. Processamento Digital de Sinais. 4.  
Inteligência Artificial. I. Ourique, Fabrício de  
Oliveira. II. Universidade Federal de Santa  
Catarina. Graduação em Engenharia de Computação. III.  
Título.

Renan Cunha dos Santos

**IDENTIFICAÇÃO DE FALHAS ESTRUTURAIS EM TELHAS  
CERÂMICAS ATRAVÉS DA ANÁLISE DE EMISSÃO  
ACÚSTICA**

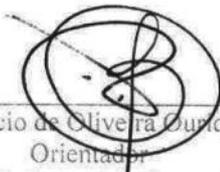
Esta monografia foi julgada adequada para obtenção do Título de  
"Bacharel em Engenharia de Computação" e aprovada em sua forma  
final pela Universidade Federal de Santa Catarina

Araranguá, 2 de Junho de 2018.



Prof. Eliane P. Zebon Dra.  
Coordenador do Curso

**Banca Examinadora:**



Prof. Fabrício de Oliveira Ourique, Dr.  
Orientador  
Universidade Federal de Santa Catarina



Prof. Gustavo Meireiros de Araújo, Dr.  
Universidade Federal de Santa Catarina



Prof. Roderval Marcelino, Dr.  
Universidade Federal de Santa Catarina







## AGRADECIMENTOS

A realização deste trabalho não seria possível sem a ajuda de determinadas pessoas. Gostaria de agradecer primeiramente o meu orientador Prof. Dr. Fabrício de Oliveira Ourique pela orientação e pelo suporte dado durante o desenvolvimento do trabalho, e principalmente por acreditar na ideia proposta.

Gostaria também de deixar meus agradecimentos ao professor Dr. Roderval Marcelino, responsável pelo LPA - Laboratório de Pesquisa Aplicada, que intermediou o contato com o SINDICER - Sindicato da Indústria da Cerâmica Vermelha (em Morro da Fumaça - SC), afim de se conseguir as amostras de telhas cerâmicas utilizadas neste estudo.

Deixo também meu muito obrigado aos meus colegas de laboratório, Yuri Crotti, Luan Carlos Casagrande e em especial para o Rodrigo Maciel, por ter me auxiliado diversas vezes durante a etapa de aquisição de dados.

Por fim, agradeço a minha família por sempre me apoiar em minhas escolhas e por me incentivar a sempre seguir em frente, vencendo os obstáculos do caminho em buscas dos meus objetivos.



*Sonhos determinam o que você quer. Ações determinam o que você conquista.*

Aldo Novak



## RESUMO

No Brasil, dentre todas as etapas do processo de produção de objetos cerâmicos, a inspeção de qualidade é a que ainda possui muita dependência humana, uma vez que é feita, em geral, de forma manual. Um teste comumente realizado para verificar a integridade de materiais cerâmicos é a análise do som emitido pelo objeto quando sujeito a uma pancada não-destrutiva. Por ser uma tarefa muito repetitiva, a análise destes sons, quando feita por seres humanos, está sujeita a possíveis falhas de julgamento, haja vista o caráter exaustivo da mesma. Desta forma, este trabalho propõe uma abordagem computacional para se identificar falhas estruturais em telhas cerâmicas, a partir do uso de processamento digital de sinais em conjunto com técnicas de aprendizado de máquina. Foram extraídas diversas características dos sinais de áudio, selecionado as mais importantes e treinado/avaliado três classificadores diferentes (*SVM - Support Vector Machine*, *LDA - Linear Discriminant Analysis* e *KNN - K-Nearest Neighbors*). Os três algoritmos de classificação testados apresentaram métricas de performance relativamente altas, com destaque para o LDA, que apresentou a melhor taxa de acerto. Os resultados deixaram claro a viabilidade técnica de se fazer a caracterização de telhas cerâmicas a partir do uso de aprendizado de máquina.

**Palavras-chave:** Processamento Digital de Sinais, Aprendizado de Máquina, Inteligência Artificial



## ABSTRACT

In Brazil, among all the steps of the production process of ceramic objects, the quality inspection is the one that still has a lot of human dependence. A commonly used test to check the integrity of ceramic materials is the analysis of the sound emitted by the object when its hit by a non-destructive impact. Because it's a very repetitive task, this sound analysis, when made by humans, is subject to judgment mistakes. Thus, this work proposes a computational approach to identify structural failures in ceramic roof tiles, using digital signal processing with machine learning techniques. It was extracted various characteristics of the audio signals, selected the most important ones and trained/evaluated three different classifiers (*SVM - Support Vector Machine*, *LDA - Linear Discriminant Analysis* and *KNN - K-Nearest Neighbors*). The three classification algorithms tested has presented very good performance metrics, highlighting the LDA, which presented the best overall accuracy. The results showed the technical viability to characterize roof tiles using machine learning.

**Keywords:** Digital Signal Processing, Machine Learning, Artificial Intelligence



## LISTA DE FIGURAS

Figura 1	Abrangência do setor de cerâmica vermelha no Brasil. .	31
Figura 2	Produção nacional de cerâmica vermelha por região. . . .	32
Figura 3	Cerâmica - Distribuição de empregos e estabelecimentos no estado de Santa Catarina. . . . .	33
Figura 4	Telhas cerâmicas: a) portuguesa, b) francesa e c) romana.	34
Figura 5	Ondas acústicas geradas em um material sólido. . . . .	37
Figura 6	Processo de extração de características. . . . .	46
Figura 7	ZCR extraídos de dois segmentos de áudios de telhas com e sem defeitos. . . . .	48
Figura 8	Energia de dois sinais de áudio distintos. . . . .	49
Figura 9	Entropia de dois sinais de áudio de telhas com e sem defeito. . . . .	50
Figura 10	Centroide espectral de dois sinais de áudios de telhas com e sem defeito. . . . .	51
Figura 11	<i>Spectral Spread</i> de dois sinais de áudios de telhas com e sem defeito. . . . .	52
Figura 12	Fluxo de execução do sistema de classificação de telhas cerâmicas . . . . .	65
Figura 13	Amostra de telha portuguesa utilizada no experimento.	68
Figura 14	Área de impacto do pistão na telha portuguesa. . . . .	68
Figura 15	Estrutura física em MDF e pistão de impacto. . . . .	69
Figura 16	Diagrama da divisão final da base de dados. . . . .	73
Figura 17	Frequência de seleção das características. . . . .	78



## LISTA DE TABELAS

Tabela 1	Especificações técnicas de telhas do tipo portuguesa ...	67
Tabela 2	Especificações das características extraídas .....	71
Tabela 3	Especificações dos parâmetros de janelamento .....	72
Tabela 4	<i>Hyperparameters</i> dos classificadores K-NN, SVM e LDA.	75
Tabela 5	Relação das características selecionadas.....	78
Tabela 6	Resultados - Seleção de parâmetros do classificador SVM (sem seleção de características).....	81
Tabela 7	Resultados - Seleção de parâmetros do classificador SVM (com seleção de características).....	81
Tabela 8	Resultados - Seleção de parâmetros do classificador K-NN (sem seleção de características).....	82
Tabela 9	Resultados - Seleção de parâmetros do classificador K-NN (com seleção de características) .....	82
Tabela 10	Resultados - Seleção de parâmetros do classificador LDA (sem seleção de características).....	83
Tabela 11	Resultados - Seleção de parâmetros do classificador LDA (com seleção de características).....	83
Tabela 12	Matriz de confusão para classificação binária .....	84
Tabela 13	Matrizes de confusão da avaliação do classificador SVM	87
Tabela 14	Matrizes de confusão da avaliação do classificador K-NN	87
Tabela 15	Matrizes de confusão da avaliação do classificador LDA	88
Tabela 16	Métricas gerais da avaliação dos classificadores .....	88



## LISTA DE ABREVIATURAS E SIGLAS

PIB	Produto Interno Bruto.....	25
EA	Emissão Acústica.....	27
kNN	K-Nearest Neighbors.....	28
SVM	Support Vector Machine.....	28
LDA	Linear Discriminant Analysis.....	28
END	Ensaio Não-Destrutivo.....	35
TDF	Transformada Discreta de Fourier.....	41
FFT	Fast Fourier Transform.....	43
ZCR	Zero-Crossing Rate.....	45
MFCC	Mel-Frequency Cepstral Coefficients.....	54
LASSO	Least Absolute Shrinkage and Selection Operator.....	57
MDF	Medium Density Fiberboard.....	67
PVC	Policloreto de Polivinila.....	67
PCA	Principal Component Analysis.....	92



## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	25
1.1 HIPÓTESE .....	27
1.2 OBJETIVOS .....	27
1.2.1 Geral .....	28
1.2.2 Específicos .....	28
1.3 JUSTIFICATIVA .....	28
1.4 METODOLOGIA .....	29
1.5 ESTRUTURA DO TRABALHO .....	30
<b>2 CERÂMICA VERMELHA</b> .....	31
2.1 CERÂMICA EM SANTA CATARINA .....	32
2.2 TELHAS CERÂMICAS .....	34
2.3 ENSAIOS PARA CONTROLE DE QUALIDADE .....	34
2.3.1 Ensaios não-destrutivos .....	35
2.3.2 Emissão Acústica .....	36
2.3.3 Controle de qualidade de telhas cerâmicas .....	38
<b>3 SINAIS DE ÁUDIO</b> .....	41
3.1 REPRESENTAÇÃO DOS SINAIS DE ÁUDIO .....	41
3.1.1 Transformada discreta de Fourier (TDF) .....	42
3.2 JANELAMENTO .....	43
3.2.1 Processamento de termo curto .....	44
3.2.2 Processamento de termo médio .....	45
3.3 EXTRAÇÃO DE CARACTERÍSTICAS .....	47
3.3.1 Características temporais .....	47
3.3.2 Características espectrais .....	51
3.4 SELEÇÃO DE CARACTERÍSTICAS .....	55
3.4.1 Métodos de Filtragem .....	56
3.4.2 Métodos <i>Wrapper</i> .....	57
3.4.3 Métodos <i>Embedded</i> .....	57
3.4.3.1 Seleção de características utilizando LASSO .....	57
<b>4 APRENDIZADO DE MÁQUINA</b> .....	59
4.1 ALGORITMOS DE CLASSIFICAÇÃO .....	59
4.1.1 <i>Linear Discriminant Analysis</i> (LDA) .....	60
4.1.2 <i>K-Nearest Neighbors</i> (k-NN) .....	60
4.1.3 Support Vector Machines (SVM) .....	61
4.2 OTIMIZAÇÃO DE PARÂMETROS .....	62
<b>5 IMPLEMENTAÇÃO DO SISTEMA</b> .....	65
5.1 AMOSTRAS .....	66

5.2 AQUISIÇÃO DE DADOS .....	67
5.3 CRIAÇÃO DA BASE DE DADOS .....	70
5.3.1 Extração de características .....	70
5.3.2 Divisão da base de dados .....	72
5.4 SELEÇÃO DE CARACTERÍSTICAS .....	73
5.5 SELEÇÃO DO MODELO DE CLASSIFICAÇÃO .....	74
<b>6 RESULTADOS .....</b>	<b>77</b>
6.1 SELEÇÃO DE CARACTERÍSTICAS .....	77
6.2 SELEÇÃO DOS MODELOS DE CLASSIFICAÇÃO .....	79
6.3 AVALIAÇÃO DOS MODELOS DE CLASSIFICAÇÃO .....	83
6.3.1 Matrizes de confusão .....	85
6.3.2 Métricas gerais da avaliação dos classificadores .....	88
<b>7 CONCLUSÃO .....</b>	<b>91</b>
<b>REFERÊNCIAS .....</b>	<b>93</b>

# 1 INTRODUÇÃO

O setor de construção civil representa 5% do Produto Interno Bruto (PIB) do Brasil, sendo que este, além de ter grande impacto na economia do país, é composto por uma série de outros setores menores (indústria de materiais de construção, ferragens, madeiras entre outros) (SILVA; M, 2017). Seguindo o crescente aumento da população no Brasil, a área da construção civil vem tendo um aumento significativo de demanda. Este aumento na demanda gerou um efeito cascata e acabou afetando também as indústrias que fornecem insumos para a execução de obras, forçando um ambiente de competitividade entre as mesmas. (RAUT; RALEGAONKAR; MANDAVGANE, 2011).

A indústria da cerâmica vermelha, que se enquadra no grupo relacionado ao fornecimento de insumos para construção civil, possui mais de 6000 fábricas distribuídas por todos estados do Brasil (ANICER, 2015). Conforme é definido em FIESC (2014), os produtos oriundos de cerâmica vermelha podem ser de dois tipos: cerâmica para revestimento ou cerâmica para construção. As cerâmicas para revestimento compreendem azulejos, ladrilhos, porcelanato e outros materiais de acabamento. Já a cerâmica para construção diz respeito a telhas, tijolos, lajotas entre outros. De acordo com ABC (2013), as regiões Sul e Sudeste foram as que mais se desenvolveram no país em relação ao potencial produtivo, produzindo cerca de 21,34% e 44,38% da produção nacional, respectivamente (SEBRAE, 2015). Este desenvolvimento se deu em razão de alguns fatores como forte atividade industrial, infraestrutura adequada para escoamento de produção, abundância de matéria-prima entre outros.

Segundo Samborski e Sadowski (2006), um dos maiores problemas enfrentados pela indústria manufatureira de objetos cerâmicos é a identificação rápida e eficiente de pequenas deformações/fissuras que podem acontecer na estrutura interna das peças e que não são facilmente identificadas através de uma inspeção visual. Estes defeitos que ocorrem no corpo de materiais cerâmicos geralmente são ocasionados durante a etapa de prensagem, devido a problemas relacionados a matéria prima utilizada ou até mesmo a falhas nos equipamentos da linha de produção (ANDRADE ENRICO ESPOSITO, 1999).

O processo de controle de qualidade (para defeitos não-visuais) tradicionalmente utilizado na indústria cerâmica é manual e consiste na audição do som produzido por uma pancada, não destrutiva, na peça que está sendo inspecionada (FALCÃO, 2002). Tal análise é feita

geralmente no fim da linha de produção e por funcionários experientes. Ainda de acordo com Falcão (2002), existem duas formas de se implementar este controle manual: por amostragem ou em toda a produção. Indústrias que produzem grandes quantidades de peças, que é o caso da indústria da cerâmica vermelha, e que possuem pouca automatização, geralmente acabam adotando uma inspeção por amostragem. Já em fábricas cuja produção é relativamente baixa, como por exemplo a produção de porcelana de cozinha, louças entre outras, é possível se fazer o controle de qualidade em todas as peças produzidas.

Com a competitividade cada vez maior entre as fabricantes de cerâmica vermelha, os consumidores, agora com mais opções, se tornam mais exigentes em relação a qualidade do produto. Em um conceito moderno, o quesito qualidade encontra-se sempre associado a produtividade e pode ser apontado como um fator decisivo da competitividade (BASTOS, 2003). Tendo isto em vista, faz-se importante a adoção de práticas que venham contribuir na otimização dos processos de produção e controle de qualidade, como por exemplo o uso de automatização de processos industriais.

Conforme discutido anteriormente, o processo de inspeção de qualidade afim de se identificar falhas estruturais em telhas cerâmicas é feito geralmente de forma manual e por amostragem.

Na literatura encontram-se algumas alternativas que buscam prover meios de se automatizar este processo tão importante e custoso do ponto de vista econômico e temporal. Dentre tais alternativas, em (AKINCI, 2011) o autor demonstra a existência de métodos baseados no uso de raio-x para se fazer a caracterização estrutural das peças cerâmicas. Porém, o mesmo deixa claro que este tipo de solução possui um alto custo de implantação, uma vez que este tipo de aparelho costuma ser relativamente caro. Ainda em (AKINCI, 2011) é comentado a respeito do uso de inspeções utilizando sensores infravermelho, porém, similarmente ao uso de raio-x, métodos baseados em infravermelho ainda são considerados caros e pouco explorado de forma geral. Outro tipo de inspeção que é muito explorado na literatura é a inspeção utilizando-se de sensores ultra-sônicos. Conforme é discutido em (ROMAGNOLI et al., 2007), o problema deste tipo de inspeção é que os transdutores do sistema ultra-sônico precisam ser acoplados fisicamente a peça em análise, ou seja, acaba se tornando de certa forma inviável a incorporação do mesmo em uma linha de produção cerâmica para funcionar em tempo real. Além de que os pulsos ultra-sônicos que serão estimulados na peça cerâmica podem gerar eco e acabar resultando em ruídos na captação do sinal desejado (RODRIGUEZ; VERGARA; MORALES, 1996).

Uma solução que vem sendo cada vez mais estudada e aplicada em diversas áreas, é o uso de técnicas de análise de emissão acústica (EA) na banda audível para a detecção de defeitos em materiais rígidos. Basicamente este tipo de sistema é composto por um ou mais microfones que fazem a captação do som gerado por uma batida mecânica na peça em análise, um braço robótico capaz de gerar a excitação mecânica na peça e uma unidade computacional capaz de realizar o processamento e a classificação do material analisado (FALCÃO, 2002). Encontra-se na literatura algumas aplicações deste tipo de solução, como por exemplo em (GODA, 2014), onde os autores apresentam um sistema capaz de identificar defeitos em estruturas de concretos complexas como dutos de escoamento de água e de drenagem, através do uso de EA. Já em (FALCÃO; VIEIRA; FERREIRA, 2003), é demonstrado uma outra aplicação desta mesma técnica, porém, neste caso os autores desenvolvem uma metodologia para fazer a classificação de tijolos de barro. Outra aplicação curiosa é descrita em (RANACHOWSKI; REJMUND, 2008), onde a técnica de EA foi utilizada para se fazer uma examinação de propriedades de materiais de porcelana com alto valor agregado. Considerando-se todas estas aplicações envolvendo o uso de técnicas de análise de emissão acústica para identificação de defeitos nos mais diversos tipos de materiais rígidos, chega-se a pergunta de pesquisa do presente trabalho: Seria possível desenvolver um sistema computacional, baseado em aprendizado de máquina, que seja capaz de classificar telhas cerâmicas de acordo com o som emitido a partir de uma batida mecânica nas mesmas?

## 1.1 HIPÓTESE

Uma vez que o som emitido por uma telha cerâmica com falhas estruturais é diferente do som emitido por uma peça considerada boa, seria possível, através de um sistema computacional de aprendizado de máquina, classificar sinais de áudio de batidas em telhas cerâmicas, visando automatizar parte da etapa de controle de qualidade em indústrias ceramistas?

## 1.2 OBJETIVOS

Esta seção apresenta o objetivo geral e os objetivos específicos do presente trabalho.

### 1.2.1 Geral

Determinar a qualidade estrutural de telhas cerâmicas através da análise de resposta acústica a uma excitação mecânica em um sistema computacional autônomo, utilizando-se de técnicas de processamento de sinais e aprendizado de máquina.

### 1.2.2 Específicos

- Identificar a diferenciação sonora através de ensaios não-destrutivos entre telhas cerâmicas consideradas boas e consideradas ruins;
- Demonstrar a possibilidade de, a partir de um grande conjunto de características, filtrar somente as que são de interesse para a determinação de qualidade da telha cerâmica;
- Comparar a acurácia dos classificadores *k-nearest neighbors* (k-NN) , *Support Vector Machine* (SVM) e *Linear Discriminant Analysis* (LDA) para a classificação da base de dados criada;
- Avaliar a influência dos *hyperparameters* (parâmetros definidos pelo usuário) dos classificadores na acurácia do sistema.

## 1.3 JUSTIFICATIVA

Conforme foi discutido anteriormente, as soluções de inspeção baseadas em artefatos como o uso de raio-x, sensores infravermelho e sensores ultra-sônicos, geralmente esbarram em dois problemas: alto custo de implantação ou falta de adequação para se implantar na linha de produção em tempo real. Considerando tais fatos, surge o interesse pelo uso de uma solução baseada na análise de emissão acústica em banda audível, uma vez que essa não depende de acoplamento de sensores nas peças cerâmicas e os dispositivos necessários para o desenvolvimento da mesma tem custo relativamente baixo.

Uma peça cerâmica quando sujeita a uma breve pancada física, emite um som com um determinado timbre e determinado decaimento temporal. De acordo com Falcão, Vieira e Ferreira (2003), este timbre e o decaimento estão diretamente ligados a qualidade estrutural desta cerâmica. Uma peça que venha conter defeitos na sua estrutura vai revelar um som mais abafado e com um decaimento temporal curto.

A explicação física do por que isto ocorre pode ser explicada de forma simplista: um material cerâmico considerado bom possui propriedades de rigidez e continuidade (sem trincas internas) bem definidas, o que acaba proporcionando uma maior velocidade de propagação acústica e uma menor atenuação das ondas sonoras.

Considerando a existência desta diferenciação sonora entre objetos cerâmicos com e sem defeitos, justifica-se a hipótese proposta de se tentar encontrar características nos sinais de áudio que diferenciem uma telha cerâmica com defeito de uma telha cerâmica sem avarias e implementar um sistema computacional capaz de realizar este processamento de forma automática, rápida e com o mínimo de intervenção humana possível.

## 1.4 METODOLOGIA

Afim de se atingir os objetivos descritos na Seção 1.2, pretende-se adotar a metodologia descritas nos passos abaixo:

1. Elaborar um referencial bibliográfico a cerca da aplicação de técnicas de análise de emissão acústica para identificação de defeitos em materiais rígidos;
2. Criar uma base de dados de sons obtidos através de batidas mecânicas nas telhas cerâmicas que serão utilizados no presente estudo;
3. Implementar os algoritmos de extração de características no domínio do tempo e da frequência, de acordo com o material de apoio demonstrado em (GIANNAKOPOULOS, 2014);
4. Realizar um estudo a respeito de técnicas de seleção de características;
5. Aplicar técnicas de seleção de características (LASSO) na base de dados afim de identificar quais características sonoras sofrem alterações de acordo com a qualidade da peça cerâmica;
6. Implementar e testar os algoritmos de classificação: *k-nearest neighbors* (k-NN), *Support Vector Machine* (SVM) e *Linear Discriminant Analysis* (LDA);
7. Avaliar a acurácia e o desempenho computacional dos algoritmos de classificação, fazendo variações nos denominados *hyperparameters* dos mesmos.

## 1.5 ESTRUTURA DO TRABALHO

Este trabalho está estruturado de tal forma que, em seguida, no Capítulo 2 será abordado aspectos relativos a cerâmica em geral. Já no Capítulo 3 serão retomados conceitos relacionados a sinais de áudio. O Capítulo 4 busca situar o leitor a respeito das técnicas de aprendizado de máquina utilizadas no trabalho. No Capítulo 5, toda a implementação do sistema é descrita de forma detalhada. Já no Capítulo 6 são apresentados os resultados obtidos em todas as etapas do trabalho. Por fim, no Capítulo 7 é feita uma conclusão sobre a execução do estudo no geral.

## 2 CERÂMICA VERMELHA

De acordo com SEBRAE (2015), a cerâmica vermelha engloba diversos materiais que são utilizados com certa frequência no ramo de construção civil. Dentre estes materiais pode-se citar os blocos de tijolos, as telhas, os ladrilhos para pisos e paredes entre outros. Ainda conforme discute o autor, o termo vermelha diz respeito a presença de compostos ferrosos na matéria prima utilizada (argila), que acabam dando uma coloração naturalmente avermelhada as peças cerâmicas.

O emprego de materiais cerâmicos é algo comum desde os tempos mais primórdios da história. Uma explicação plausível para isto é o fato de que a argila, matéria prima necessária para a fabricação destes objetos, sempre foi algo abundante e de fácil extração na natureza. Apesar de existirem algumas variações nos processos de produção, geralmente a fabricação de cerâmicas consiste na moldagem, secagem e cozimento de argilas ou de misturas contendo argilas (BAUER, 1994).

Conforme (FIESC, 2015), a abrangência do setor de cerâmica vermelha pode ser dividida em dois grupos (revestimentos e materiais para construção), conforme pode-se ver na Figura 1.

Figura 1 – Abrangência do setor de cerâmica vermelha no Brasil.



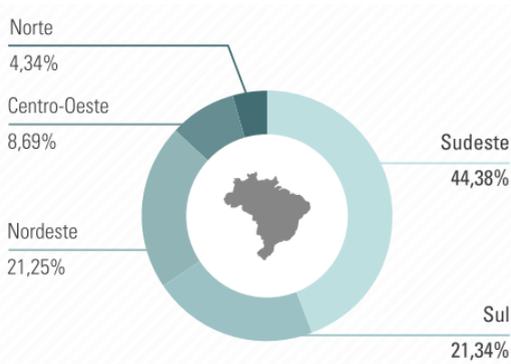
Fonte: extraída de (FIESC, 2015).

O segmento da cerâmica vermelha no geral, possui uma representatividade muito grande em diversos aspectos no país, representando cerca de 4,8% da indústria da construção civil, gerando aproximadamente 300 mil empregos diretos e 1,5 milhão de empregos indiretos, faturando R\$ 18 bilhões anualmente. Em relação a produção, estima-se que são produzidas 1,3 bilhão de telhas e 4 bilhões de blocos de vedação e estruturais por mês. Um outro dado muito importante de se destacar é que o setor não é monopolizado, sendo composto por

aproximadamente 9.071 pequenas empresas (SEBRAE, 2015).

Segundo MEDEIROS (2006), apesar de ser um setor composto por diversas empresas espalhadas pelo país, pode-se dizer que estes estabelecimentos estão majoritariamente concentrados nas regiões sul e sudeste do país, mais especificamente nos estados de São Paulo, Santa Catarina e Rio Grande do Sul. Ainda conforme destaca o autor, a alta densidade demográfica, a forte atividade industrial e a infra-estrutura adequada destas regiões, associado as facilidades de se obter matérias-primas, acabam contribuindo para esta concentração nos estados destacados. A Figura 2 demonstra a produção nacional de cerâmica vermelha por região.

Figura 2 – Produção nacional de cerâmica vermelha por região.



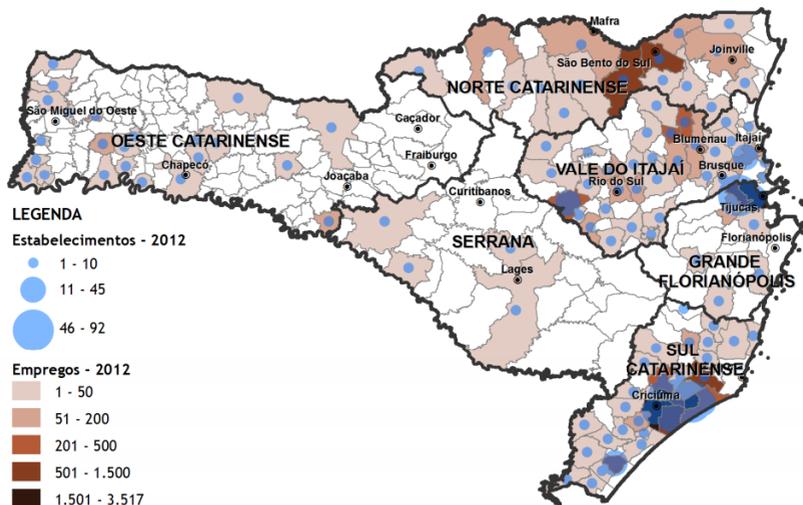
Fonte: extraída de SEBRAE (2015).

## 2.1 CERÂMICA EM SANTA CATARINA

O setor cerâmico em Santa Catarina, mais especificamente nas regiões sul do estado, é considerado um dos pólos de produção cerâmica no Brasil. Segundo EBERTZ (2005), as regiões compostas pelos municípios de Criciúma, Tubarão, Urussanga e Imbituba passaram a se destacar a nível nacional devido a uma política de substituição de importação de materiais cerâmicos por uma produção local. Ainda conforme retrata o autor, esta substituição teve um suporte financeiro do Banco Nacional de Desenvolvidos - BNDES.

Apesar de se existir empresas cerâmicas espalhadas no território do estado, é na região sul que se encontra a maior quantidade de estabelecimentos e, conseqüentemente, uma alta geração de emprego, conforme fica evidente na Figura 3.

Figura 3 – Cerâmica - Distribuição de empregos e estabelecimentos no estado de Santa Catarina.



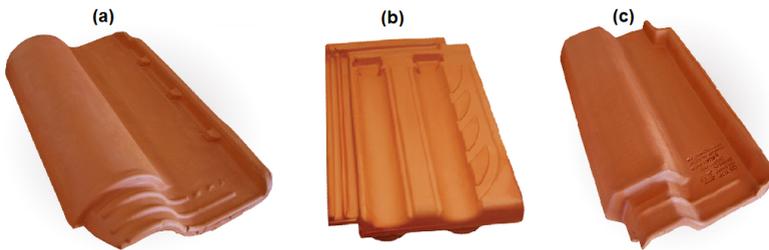
Fonte: extraída de FIESC (2015).

De acordo com visitas realizadas pelo presente autor deste trabalho, na região sul do estado de Santa Catarina, mais especificamente em municípios nos arredores de Criciúma, é possível identificar dois tipos de indústrias cerâmicas: as indústrias que produzem revestimentos (majoritariamente azulejos e porcelanato) e telhas cerâmicas, e as indústrias que se concentram em produzir, principalmente, materiais para construção, como blocos estruturais (tijolos). Geralmente, as empresas que produzem revestimentos e telhas cerâmicas possuem instalações maiores, são empresas de médio e/ou grande porte e contam com um certo grau de automatização na linha de produção. Já nos estabelecimentos que produzem blocos estruturais, ainda existe uma certa ausência de tecnologia e o processo é altamente dependente de mão de obra humana.

## 2.2 TELHAS CERÂMICAS

As telhas cerâmicas, cuja atividade de produção é muito alta no sul do estado de Santa Catarina, podem ser consideradas como uma das opções mais antigas e acessíveis para se utilizar como cobertura de construções em geral. As mesmas possuem uma boa relação custo-benefício, além de se adaptarem bem ao clima tropical (SOUZA, 2018). Conforme é tratado em Falcão (2002), na sua grande maioria as mesmas são fabricadas em série e de forma individual. As telhas cerâmicas possuem alguns formatos, sendo que no Brasil, os mais comuns são as telhas do tipo romana, portuguesa e francesa. A Figura 4 apresenta o formato destes três tipos mais comuns.

Figura 4 – Telhas cerâmicas: a) portuguesa, b) francesa e c) romana.



Fonte: extraídas de [www.ceramicasalinas.com](http://www.ceramicasalinas.com) e [www.telhassantacatarina.com.br](http://www.telhassantacatarina.com.br).

Um estudo feito por Júnior (2008) constatou que no estado de Santa Catarina os dois tipos de telhas mais comuns são as romanas e as portuguesas. Apesar de se haver uma forte semelhança física entre estes dois modelos, no presente estudo optou-se por se utilizar telhas do tipo portuguesa, exemplificadas pelo item a) da Figura 4.

## 2.3 ENSAIOS PARA CONTROLE DE QUALIDADE

Atualmente existem diversos tipos de ensaios (testes) que visam caracterizar propriedades físicas de objetos em geral. A identificação destas características estruturais dos objetos é de grande importância, principalmente em processos fabris onde peças são produzidas em série e geralmente com determinado grau de automação. De acordo com

Zolin (2011), estes ensaios permitem que se tenha um conhecimento sobre o estado do material produzido e conseqüentemente consegue-se manter o controle de qualidade e dos problemas de manufatura, a garantia de satisfação do cliente, a prevenção de acidentes e até mesmo a redução de custos.

Entre os tipos de ensaios mais comuns na indústria destaca-se os ensaios mecânicos. Estes ensaios consistem na aplicação de algum tipo de efeito mecânico (tração, compressão, torção, cisalhamento entre outros) ao objeto a ser testado, visando analisar a resposta desse objeto em relação a esse efeito externo.

Tanto a nível nacional quanto internacional, os ensaios mecânicos são categorizados em dois grandes grupos: ensaios destrutivos e ensaios não-destrutivos. Como fica evidente através dos respectivos nomes atribuídos a estes ensaios, em um ensaio destrutivo é aplicado uma força externa ao material em análise, de tal forma que algumas propriedades físicas do objeto acabam sendo alteradas permanentemente. Já no caso dos ensaios não-destrutivos os objetos testados também são submetidos a algum tipo interação externa, porém, neste caso os mesmos se mantêm intactos, ou seja, não há nenhuma deformação permanente na disposição física do material (ZOLIN, 2011).

### 2.3.1 Ensaios não-destrutivos

Segundo Shen et al. (2017), no geral, os ensaios não-destrutivos (END) acabam sendo preferidos em relação aos destrutivos, haja vista que desta maneira os objetos a serem testados não precisam ser descartados. Conforme é discutido em ABENDI (2017), os END estão entre as principais ferramentas de controle de qualidade de materiais em geral em diversos setores como petroquímico, químico, aeroespacial, siderúrgico, naval, eletromecânico, cerâmico entre outros. Existem algumas organizações que definem diretrizes a respeito deste tipo de ensaio. No Brasil, por exemplo, tem-se a ABENDI - Associação Brasileira de Ensaios Não-Destrutivos e Inspeção. Já nos Estados Unidos existe a ASNT - The American Society for Nondestructive Testing.

Conforme ABENDI (2017), no Brasil as principais técnicas de ensaios não-destrutivos aplicados em produção são:

- Correntes Parasitas;
- Radiografia;
- Emissão Acústica;
- Ensaio Visual;

- Estanqueidade;
- Líquido Penetrante;
- Partículas Magnéticas;
- Ultrassom;
- Termografia.

Apesar de existirem diversas técnicas não-destrutivas cujas finalidades estão concentradas na exploração da qualidade estrutural interna dos objetos, é preciso fazer algumas considerações quanto as formas de implementação das mesmas, os custos envolvidos entre outras. Em Tong, Tso e Xu (2006), por exemplo, os autores comentam sobre a dificuldade em se inspecionar paredes de grandes prédios através do uso de técnicas como o ultrassom, haja vista a necessidade de contato contínuo entre os sensores ultrassônicos e o objeto analisado. Além disso, em Jiang, Luk e Liu (2009) é discutido sobre o alto custo dos métodos baseados em sensores ópticos como ensaios visuais na banda do visível, ou até mesmo nos ensaios termográficos.

Uma alternativa de ensaio não-destrutivo que vem cada vez mais sendo aplicada e aprimorada, principalmente para inspeção de estruturas no geral, é a análise de emissão acústica. A explicação para isso se dá pois a mesma possibilita uma implementação, certas vezes, mais simples e, dependendo dos sensores utilizados, com o custo mais baixo, se comparado com as outras técnicas de END (raio-X, ultrassom, termografia, radiografia entre outras).

### 2.3.2 Emissão Acústica

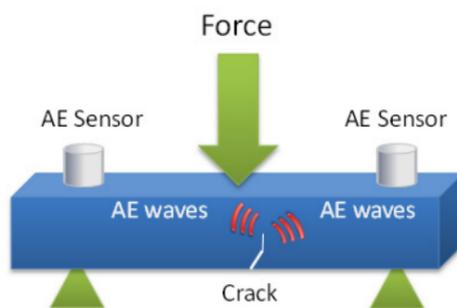
O termo Emissão Acústica, do inglês *Acoustic Emission* (AE), pode ser definido como uma área cuja finalidade compreende o estudo e o uso prático de ondas elásticas geradas por um determinado material sujeito a algum tipo de perturbação externa. De acordo com Nazarchuk, Skalskyi e Serhiyenko (2017), ondas elásticas ou acústicas são distúrbios mecânicos que se propagam em forma de onda em um meio elástico. Ainda conforme trata o autor, um exemplo de onda acústica é o som audível para o homem (20Hz até 20kHz).

Historicamente falando, pode-se dividir a área de emissão acústica em dois períodos distintos: pré-tecnológico e tecnológico. O período pré-tecnológico diz respeito a quando o ser humano conciliava a sua inteligência, o seu conhecimento e o senso comum para escutar intencionalmente eventos específicos afim de se determinar se havia a existência de risco ou não. Um exemplo disso é apresentado em Beattie (2013), onde comenta-se sobre o fato de que mineiros experientes con-

seguiram detectar possíveis desabamentos no interior de minas a partir de sinais sonoros expelidos pelas rochas prestes a ruir.

Em Muravin (2009), os autores definem EA como sendo um fenômeno de radiação de ondas sonoras e/ou ultrassônicas em materiais submetidos a algum tipo de stress durante os processos de deformação ou ruptura. Ainda de acordo com o mesmo autor, os métodos não-destrutivos baseados em emissão acústica consistem na detecção, localização e análise das ondas acústicas geradas nas estruturas sob a ação de alguma força externa, como pode-se visualizar na Figura 5.

Figura 5 – Ondas acústicas geradas em um material sólido.



Fonte: extraída de (MURAVIN, 2009).

A detecção de EA é feita por sensores (piezoelétricos, ultrassônicos, microfones) dispostos no entorno (com ou sem contato) da estrutura observada. Em alguns casos são utilizados mais de um sensor no mesmo objeto com a finalidade de se fazer, além da detecção, a localização da falha. A análise de alguns aspectos dos sinais sonoros gerados como amplitude, energia, características de frequência e entre outras provê informações valiosas sobre as condições físicas do material analisado e permite realizar inferências sobre a existência ou não de problemas relacionados a qualidade da peça. Apesar de se existir todo um procedimento para a realização de testes por emissões acústica, é muito comum se ver, na indústria em geral, a implementação desta técnica de forma rudimentar, ou seja, o inspetor aplica a força no material através de uma batida não-destrutiva e ele próprio chega a uma conclusão em relação ao estado da peça, a partir do que ele escutou.

### 2.3.3 Controle de qualidade de telhas cerâmicas

Para Ishikawa (1993), o processo de controle de qualidade em uma empresa de manufatura visa desenvolver e comercializar produtos com qualidade garantida, mais úteis e mais satisfatórios ao cliente final. Ainda conforme destaca o autor, esse processo tem como objetivo identificar não-conformidades nos produtos produzidos e, de acordo com a severidade das mesmas, aplicar ações corretivas no processo de produção e/ou nos próprio materiais falhos.

Em se tratando de telhas cerâmicas, no geral, é imprescindível que os objetos produzidos possuam as seguintes características:

- Ausência de fissuras, lascas e quebras que prejudiquem de alguma forma o uso da mesma;
- Queima adequada uniforme;
- Alta resistência mecânica;
- Entre outras características.

No Brasil existem uma série de normas técnicas que norteiam o controle de qualidade de telhas cerâmicas. Conforme é elencado em Pereira (2006), as principais normas do setor são:

- NBR6462/NB54 de 03/1987 (ABNT, 1987) – Telha cerâmica tipo francesa e romana – determinação da carga de ruptura à flexão;
- NBR7172 de 03/1987 (ABNT, 1987a) – Telha cerâmica tipo francesa;
- NBR8038 (ABNT, 1987b) – Telha cerâmica tipo francesa – padronização de formas e dimensões;
- NBR8947/NB2133 de 07/1985 (ABNT, 1985) – Telha cerâmica – determinação da massa e da absorção de água;
- NBR8948/NB2133 de 07/1985 (ABNT, 1985a) Telha cerâmica – verificação da impermeabilidade;
- NBR13582 de 02/1996 (ABNT, 1996) – Telha cerâmica tipo romana – determinação das características dimensionais (especificação).

Os processos de controle de qualidade para se assegurar que as telhas produzidas atendam as especificações determinadas pelas normas acima citadas são dos mais variados tipos. Pode-se encontrar testes que são aplicados por amostragem (aleatórios), assim como também pode-se encontrar inspeções incorporadas na própria linha de produção. Essas inspeções na linha de produção podem ser automatizadas ou não, sendo que nos casos onde ela não é automatizada, a mesma é feita por profissionais técnicos treinados para realizar este tipo de teste.

Como já foi mencionado em seções anteriores, os testes por emissão acústica são muito utilizados na indústria cerâmica. Nas cerâmicas visitadas no entorno de Criciúma - SC pode-se ver que o processo de controle de qualidade, em sua maioria, acontecia logo após as telhas saírem do forno e eram divididos em duas etapas: a primeira era uma etapa visual, onde o inspetor analisava defeitos visíveis nas peças, e a outra era uma análise feita através de emissão acústica. Na inspeção por emissão acústica, um operário experiente efetuava uma pancada não-destrutiva na telha analisada com um martelo de um polímero chamado *Technyl* e com pontas arredondas. Em algumas situações pode-se também utilizar um martelo com ponta metálica, porém, neste caso, é preciso ter mais cuidado para não danificar a peça inspecionada.

De acordo com Falcão (2002), este tipo de abordagem onde a inspeção é feita através da audição humana pode acarretar em uma série de problemas, tanto para o operador quanto para a eficiência do processo. Como é uma tarefa altamente exaustiva, pois toda peça precisa ser examinada, o profissional pode acabar tendo problemas físicos devido ao esforço repetitivo. Já em relação a eficiência do processo, o autor destaca que a sensibilidade auditiva do que é uma telha em boa condição e o que é uma telha em má condição pode variar de funcionário para funcionário, logo, não há um padrão no quesito qualidade. Além de que a confiabilidade da operação fica comprometida uma vez que o inspetor pode fazer interpretações errôneas se não estiver totalmente concentrado no processo.



### 3 SINAIS DE ÁUDIO

Neste capítulo são apresentados alguns conceitos sobre sinais de áudio, explanando desde assuntos sobre formas de representação dos sinais, transformações para outros domínios, processamento utilizando janelas, obtenção de características temporais e espectrais, entre outros.

#### 3.1 REPRESENTAÇÃO DOS SINAIS DE ÁUDIO

Apesar dos sinais de áudio serem naturalmente contínuos no tempo, no mundo digital este tipo de sinal é representado de forma discreta. Para ser mais específico, computacionalmente falando um sinal de áudio é representado por um vetor de números reais. O processo que transforma um sinal de áudio contínuo, oriundo de uma fonte qualquer, em um sinal discreto é chamado de amostragem (*sampling*). Maiores detalhes sobre o funcionamento exato do processo de amostragem pode ser vista em Giannakopoulos (2014), porém, é importante ressaltar que esse processo possui dois parâmetros essenciais que são o período de amostragem,  $T_s$ , e a frequência de amostragem,  $F_s$ . Estes dois parâmetros são diretamente proporcionais, de tal forma que  $F_s = \frac{1}{T_s}$ . De uma forma simplificada,  $F_s$  diz respeito a taxa com a qual o sinal contínuo será amostrado, afim de se gerar o vetor de valores reais que representa o sinal analisado no domínio do tempo.

De acordo com Proakis e Manolakis (2006), a análise de sinais, no geral, pode ser feita a partir de duas perspectivas: análise no domínio do tempo e análise no domínio da frequência. A análise no domínio do tempo concentra-se em averiguar aspectos relacionados a como o sinal se modifica com o tempo. Já a análise no domínio da frequência, as vezes chamada de análise espectral, mostra como a energia do sinal está distribuída sobre uma determinada faixa de frequências. Um sinal pode ser convertido entre o domínio do tempo e da frequência através de operações matemáticas denominadas transformadas. Um exemplo dessas transformadas é a transformada discreta de Fourier (TDF), que decompõe uma função em uma soma de componentes senoidais.

### 3.1.1 Transformada discreta de Fourier (TDF)

A transformada discreta de Fourier (TDF) é de enorme importância em qualquer área que envolva processamento digital de sinais. Essa transformada é utilizada para derivar uma representação espectral de um determinado sinal, ou seja, levar o mesmo para o domínio da frequência. Conforme será discutido em seções a seguir, diversas características dos sinais de áudio, que irão servir para se fazer a análise dos mesmos, estão definidas no domínio da frequência (GIANNAKOPOULOS, 2014).

Dado um sinal discreto no domínio do tempo  $x(n)$ , tal que  $n = 0, \dots, N - 1$ , sendo  $N$  o comprimento do sinal, a sua TDF é definida pela Equação 3.1:

$$X(k) = \sum_{n=0}^{N-1} x(n)e^{-j\frac{2}{N}kn}, k = 0, \dots, N - 1 \quad (3.1)$$

onde  $j \equiv \sqrt{-1}$ . Pode-se concluir que o resultado dessa transformada é uma sequência de  $N$  coeficientes complexos. Estes  $X(k)$ s coeficientes complexos constituem a representação do sinal no domínio da frequência. A transformada inversa (TDIF) é capaz de pegar como entrada os coeficientes da TDF e recompor o sinal original (no domínio do tempo), conforme segue a Equação 3.2:

$$x(n) = \frac{1}{N} \sum_{k=0}^{N-1} X(k)e^{j\frac{2}{N}kn}, k = 0, \dots, N - 1 \quad (3.2)$$

Deste forma, é importante ressaltar que as representações dispostas pelas Equações 3.1 e 3.2, são equivalentes.

Em seções seguintes, quando será discutida a extração de características, serão computados algumas métricas a partir do sinal no domínio da frequência. Porém, para fins de entendimento prévio, uma interpretação interessante dos coeficientes da TDF é que, seja  $F_s$  a frequência de amostragem utilizada para obter o sinal  $x(n)$ , então a  $k$ -ésima exponencial corresponde a frequência  $f_k = k\frac{F_s}{N}$ , onde  $k = 0, \dots, N - 1$ . Uma outra discussão muito útil em termos práticos que se pode fazer sobre o sinal no domínio da frequência envolve a magnitude do  $k$ -ésimo coeficiente,  $|X(k)|$ , que pode ser interpretada como uma medida da intensidade em que a respectiva frequência possui no sinal  $x(n)$ . As fases dos coeficientes da TDF também podem ser utilizadas para uma série de aplicações, porém, a grande maioria dos métodos

de extração de características são baseados apenas na magnitude dos coeficientes (GIANNAKOPOULOS, 2014).

Computacionalmente falando, a implementação da TDF é relativamente custosa. Para ser mais exato, conforme é matematicamente apresentado em Roberts (2003), o custo é diretamente ligado a  $N^2$ , que é o custo da multiplicação matricial de um vetor. Porém, ainda conforme discute o autor no mesmo trabalho, desde a década de 60 foram desenvolvidos algoritmos altamente eficientes para se calcular esta transformada, sendo que estes algoritmos são conhecidos como *Fast Fourier Transform* (FFT). Estes algoritmos exploram as redundâncias computacionais existentes nas equações que definem a TDF e a sua inversa.

### 3.2 JANELAMENTO

Na maioria das aplicações de processamento digital de sinais as análises são feitas a partir de técnicas de janelamento, também conhecidas por *short-term processing*. Este tipo de processamento consiste em dividir o sinal de áudio em pequenas janelas, com sobreposição ou não, e aplicar as análises individualmente nestes quadros menores. Segundo Theodoridis e Koutroumbas (2008), a explicação do por que esta técnica de janelamento ser geralmente utilizada se dá devido ao fato de que sinais de áudio são não-estacionários por natureza, ou seja, suas propriedades variam (geralmente de forma rápida) com o tempo.

Em Theodoridis e Koutroumbas (2008) é discutido um caso que exemplifica com clareza o significado de um sinal não-estacionário. Considere uma gravação de áudio de uma conversa rápida (duração de 1s) entre duas pessoas, seguida por um grito de uma terceira pessoa (com duração de 1s). Basicamente este trecho de áudio é composto por dois eventos principais: a conversa entre os dois indivíduos (sinal de intensidade normal) e o grito (sinal de alta intensidade). É evidente que existe uma mudança abrupta entre o estado da conversação e o estado do grito. Conforme o autor discute, de uma perspectiva simplificada, esta mudança pode ser considerada como uma mudança de estacionariedade. Nessas situações fica claro que não faz sentido calcular, por exemplo, a intensidade do sinal como um todo, uma vez que o resultado seria dominado pela parte mais intensa, que nesse caso foi o grito. Desta maneira, uma forma mais eficiente de fazer esse processo, considerando todo o áudio, seria quebrar o áudio em pequenas segmentos, que podem ser chamados de quadros (*frames*) ou janelas (*windows*), e

então calcular, por exemplo, um valor da intensidade para cada segmento. Geralmente este valor único valor extraído de cada segmento é um valor estatístico (média, mediana, desvio padrão, *max*, *min* entre outros).

### 3.2.1 Processamento de termo curto

Conforme discutido anteriormente, os sinais de áudio são analisados de uma forma segmentada através do uso de uma técnica chamada de processamento de termo curto ou *short-term processing*. Considerando  $x(n)$ ,  $n = 0, \dots, N - 1$  um sinal de áudio com  $N$  amostras, neste tipo de processamento em cada etapa da análise o sinal de áudio é multiplicado por uma versão deslocada de uma função de janelamento finita, que neste caso será tratada como  $w(n)$  (GIANNAKOPOULOS, 2014). Um exemplo muito simples de uma função de janelamento seria uma função que assume o valor zero sempre que o sinal estiver fora de um determinado intervalo.

O sinal resultante  $x_i(n)$  na  $i$ -ésima etapa do janelamento é dado pela Equação 3.3:

$$x_i(n) = x(n)w(n - m_i), i = 0, \dots, K - 1, \quad (3.3)$$

onde  $K$  é o número total de quadros e  $m_i$  é o número de amostras pela qual a janela será deslocada para produzir o  $i$ -ésimo quadro. Analisando a Equação 3.3 pode-se ver que  $x_i(n)$  é zero em todos locais, exceto na região com índices  $m_i, \dots, m_i + W_L - 1$ , sendo que  $W_L$  é o comprimento (em amostras) da janela. O valor de  $m_i$  depende de um outro parâmetro muito importante da janela que é o passo (*step*), definido por  $W_s$ . Por exemplo, suponha uma janela que se desloca 10ms a cada etapa e uma frequência de amostragem  $F_s$  de 16kHz, então,  $m_i = i \times W_s \times F_s = i \times 160$  amostras. Considerando um comprimento  $W_L = 300$ , então, o quinto quadro ( $i = 4$ ) começaria na amostra de índice  $160 \times 4 = 640$  e terminaria na amostra de índice  $160 \times 4 + 300 - 1 = 939$ .

A partir das análises feitas acima percebe-se que a etapa de janelamento possui três parâmetros muito importantes que são o comprimento da janela,  $W_L$ , o seu passo (*step*),  $W_s$  e o seu tipo (função utilizada para implementar a janela). Segundo Giannakopoulos (2014) e Nandhini Shenbagavalli e Scholar (2014), geralmente o valor de  $W_L$  varia entre 10ms e 50ms. Já em relação ao passo da janela,  $W_s$ , supondo, por exemplo, que a sobreposição de janelas desejada seja de

75% e que  $W_L$  seja 50ms, então o passo  $W_s$  deverá ser 10ms. Dessa forma, tem-se que o número total de quadros gerados nessa situação hipotética seria descrito pela Equação 3.4:

$$\lfloor \frac{N - W_L}{W_s} \rfloor + 1, \quad (3.4)$$

onde  $\lfloor \cdot \rfloor$  é o operador *floor*.

Em relação ao tipo da janela, pode-se dizer que a opção mais simples seria uma janela retangular, que como o próprio nome já evidencia, apenas torna nulo o sinal nos locais que estão fora dos limites da janela. Porém, existem outras opções que também costumam ser utilizadas para este tipo de tarefa, como a janela de *Hamming*, a janela de *Bartlett* e a janela de *Hanning*. A diferença entre estas funções de janelamento estão apenas na forma a qual a janela irá tomar após se aplicar as mesmas.

É muito comum ver na literatura o uso da janela de *Hamming*. No presente estudo este tipo de janela foi utilizado no processo de janelamento. De acordo com Oppenheim, Schafer e Buck (1999), esta janela é definida pela Equação 3.5, conforme segue abaixo:

$$w(n) = 0,54 - 0,46\cos(2\pi\frac{n}{N}), 0 \leq n \leq N, \quad (3.5)$$

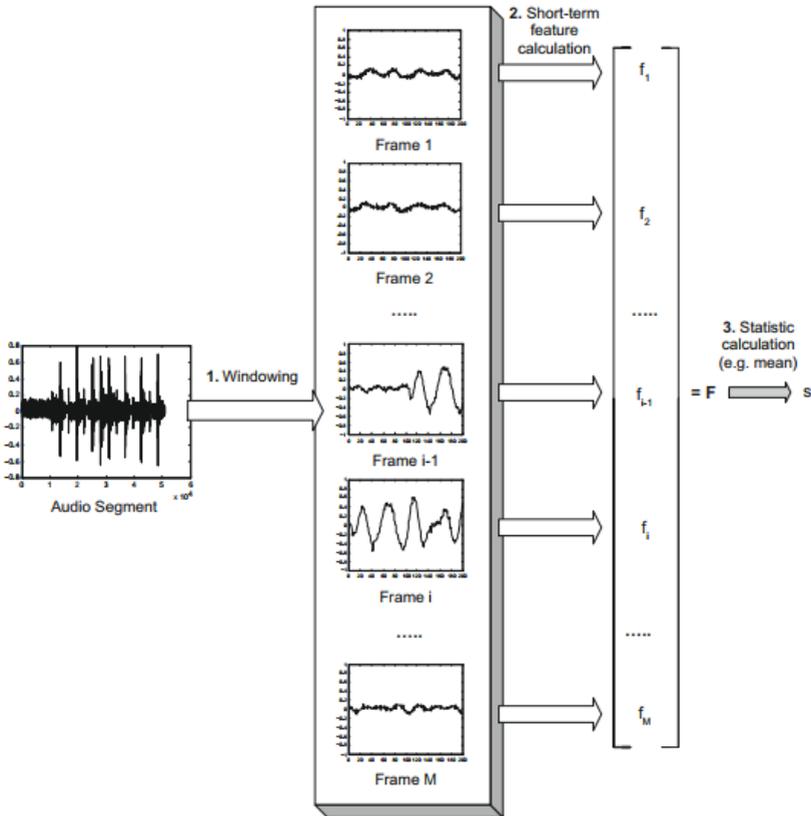
sendo  $L = N + 1$  o tamanho da janela.

### 3.2.2 Processamento de termo médio

Uma outra abordagem muito comum, utilizada em tarefas que envolvam o reconhecimento de padrões em áudio, é o processamento de termo médio. Nesse tipo de processamento, o sinal é primeiramente dividido em termos médios (*mid-terms*), que são apenas segmentos do áudio original, sendo que para cada um destes segmentos, é aplicado o processamento de termo curto, visto na sub-seção 3.2.1. Em seguida, o vetor  $\mathbf{F}$ , que contém as características de termo curto, é utilizado para calcular uma série de estatísticas, como por exemplo o valor médio do *Zero-Crossing Rate* (ZCR) ou o desvio padrão da energia. Ao final do processamento, cada segmento de termo médio é composto por um conjunto de estatísticas que descrevem as características extraídas em termo curto. Conforme Giannakopoulos (2014), normalmente a duração de um segmento de termo médio está entre 1 e 10 segundos, dependendo da aplicação. A Figura 6 demonstra como é realizado a

extração de características utilizando este tipo de abordagem.

Figura 6 – Processo de extração de características.



Fonte: extraída de (GIANNAKOPOULOS, 2014).

Para exemplificar este tipo de processamento, analisando o fluxo disposto na Figura 6 e supondo um cenário onde para cada janela de tempo curto sejam extraídas 23 características. Considere também que para cada característica sejam calculadas duas estatísticas (média e desvio padrão). Dessa forma, caso fosse utilizado apenas um segmento de médio termo, o resultado final do processamento como um todo seria um vetor de 46 posições, sendo que as posições 1 e 24 iriam conter a média e o desvio padrão da primeira característica, respectivamente.

Já a posição 2 e 25 iriam conter a média e o desvio padrão da segunda característica, e assim sucessivamente. É importante destacar que no presente trabalho também foi utilizado apenas um segmento de médio termo, ou seja, cada estatística foi calculada apenas uma vez para cada característica analisada, no áudio como um todo.

### 3.3 EXTRAÇÃO DE CARACTERÍSTICAS

Segundo Cardoso (2001), dado um grande conjunto inicial de variáveis físicas, o processo de extração de características consiste na geração de um novo conjunto de variáveis com melhor capacidade de discriminação e tamanho menor do que o conjunto inicial. Outro fator importante a se destacar é que geralmente este novo conjunto gerado acaba perdendo seu significado físico. Conforme é discutido em Rao (2008), a extração de características tem um papel muito importante na área de processamento digital de sinais, haja vista que é através desta que se consegue montar uma representação numérica mais sucinta do sinal acústico e, conseqüentemente, fazer a caracterização do mesmo. Em Giannakopoulos (2014), o autor cita que a extração de características é uma etapa essencial em tarefas de reconhecimento de padrões e de aprendizado de máquina. Para Lee e Landgrebe (), visando a área de reconhecimento de padrões, é desejado que se consiga extrair características que sejam capaz de discriminar dados entre duas ou mais classes.

Apesar de se existir um grande número de características que podem ser extraídas de sinais de áudio, será descrito abaixo um conjunto de características que são discutidas em Giannakopoulos (2014). Para fins de organização e melhor entendimento, as características foram divididas em dois grupos: temporais e espectrais.

#### 3.3.1 Características temporais

Nesta sub-seção serão descritas algumas características extraídas do sinal no domínio do tempo.

##### 3.3.1.1 *Zero-Crossing Rate* (ZCR)

O *Zero-Crossing Rate* (ZCR) pode ser definido como a taxa de passagem por zero de um quadro de áudio, ou seja, a taxa de mudança

de sinal de um determinado áudio. Ele é definido pelo número de vezes que o sinal muda de positivo para negativo e vice-versa, dividido pelo comprimento do quadro. A Equação 3.6 apresenta a expressão que determina o ZCR:

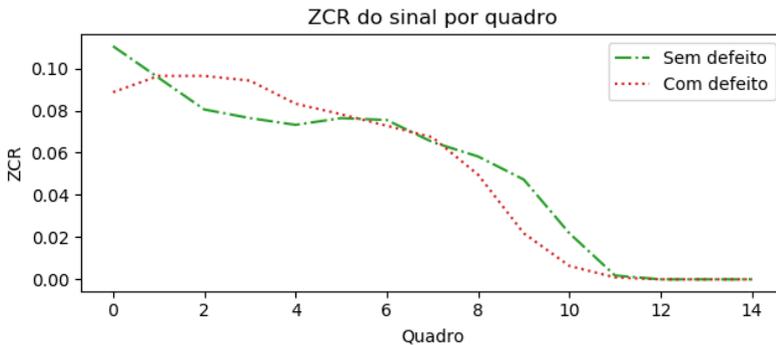
$$Z(i) = \frac{1}{2W_L} \sum_{n=1}^{W_L} W_L |sgn[x_i(n)] - sgn[x_i(n-1)]| \quad (3.6)$$

onde  $sgn(\cdot)$  é definida pela função apresentada na Equação 3.7:

$$sgn[x_i(n)] = \begin{cases} 1, & x_i(n) \geq 0 \\ -1, & x_i(n) < 0 \end{cases} \quad (3.7)$$

De acordo com Giannakopoulos (2014), os valores de ZCR geralmente são altos nas partes do sinal onde se tem mais ruídos. A Figura 7 apresenta a evolução do ZCR de dois sinais de áudios distintos, oriundos de pancadas não destrutivas em telhas com e sem defeitos.

Figura 7 – ZCR extraídos de dois segmentos de áudios de telhas com e sem defeitos.



Fonte: próprio autor.

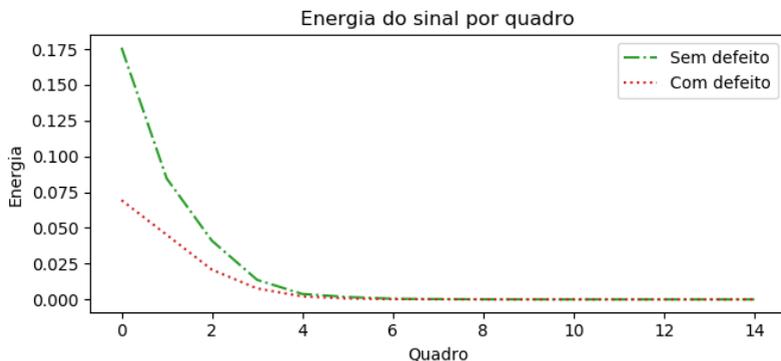
### 3.3.1.2 Energia

A energia provê informação a respeito da intensidade e da atividade do sinal. Seja  $x_i(n)$ ,  $n = 1, \dots, W_L$  a sequência de amostras contida no  $i$ -quadro de análise, a energia do mesmo pode ser obtida pela Equação 3.8.

$$E(i) = \sum_{n=1}^{W_L} |x_i(n)|^2 \quad (3.8)$$

A Figura 8 demonstra um gráfico da energia de dois sinais distintos. O primeiro sinal (verde) é o som da batida em uma telha cerâmica considerada boa, já o outro sinal (vermelho) é da batida em uma telha cerâmica com alguma falha estrutural interna. Como pode-se perceber, fica evidente que a telha falhada possui uma energia menor se comparado com a telha intacta.

Figura 8 – Energia de dois sinais de áudio distintos.



Fonte: próprio autor.

### 3.3.1.3 Entropia

Na análise de *short-term* a entropia pode ser interpretada como a quantificação de mudanças abruptas que ocorrem no sinal. Para extrair a entropia de um sinal, primeiro divide-se cada  $quadro_i$ , obtido no ja-

nelamento, em  $K$  sub-quadros. Então, para cada sub-quadro  $j$  calcula-se a energia conforme descrito na Equação 3.8 e divide-se a mesma pela energia total  $E_{quadro_i}$  do quadro de análise. No presente trabalho optou-se por adotar  $K = 10$ . A energia normalizada do *subquadro<sub>j</sub>* é dada pela Equação 3.9, sendo que  $j = 1, \dots, K$ .

$$e_j = \frac{E_{subquadro_j}}{E_{quadro_i}} \quad (3.9)$$

Onde:

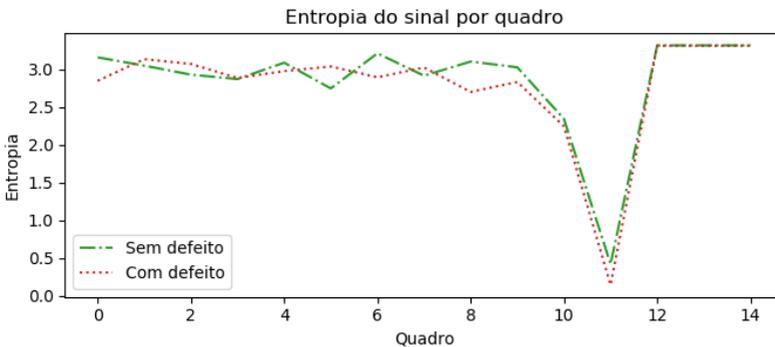
$$E_{quadro_i} = \sum_{k=1}^K E_{subquadro_k} \quad (3.10)$$

Finalmente, a entropia  $H(i)$  é calculado através da Equação 3.11.

$$H(i) = - \sum_{j=1}^K e_j \times \log_2(e_j) \quad (3.11)$$

A Figura 9 demonstra a entropia calculada para dois sinais de áudio, um de uma telha com defeito e outro de uma telha sem nenhum tipo de defeito estrutural.

Figura 9 – Entropia de dois sinais de áudio de telhas com e sem defeito.



Fonte: próprio autor.

### 3.3.2 Características espectrais

Nesta sub-seção serão descritas algumas características extraídas do sinal no domínio da frequência, mais especificamente, dos coeficientes obtidos através da aplicação da TDF.

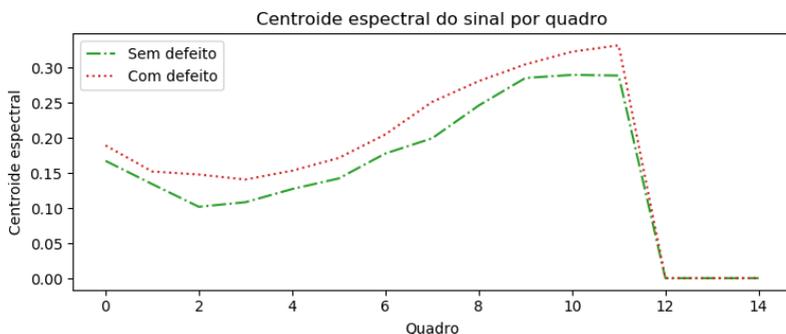
#### 3.3.2.1 Centroide espectral

A centroide espectral é uma medida que identifica o centro de massa de um sinal. Tendo em vista que o espectro de frequência do som emitido pela batida no piso cerâmico segue sempre um padrão, espera-se que a centroide espectral também siga um padrão, dependendo do tipo do piso analisado. Seja  $|X_i(k)|$ ,  $k = 1, \dots, W_{FL}$  a magnitude dos coeficientes da transformada discreta de Fourier (TDF) do *quadro*<sub>*i*</sub>, e centroide espectral  $C_i$  do *quadro*<sub>*i*</sub> pode ser calculada através da Equação 3.12.

$$C_i = \frac{\sum_{k=1}^{W_{fL}} k |X_i(k)|}{\sum_{k=1}^{W_{fL}} |X_i(k)|} \quad (3.12)$$

A Figura 10 apresenta um exemplo do cálculo das centroides espectrais de dois sinais obtidos de amostras com e sem defeitos.

Figura 10 – Centroide espectral de dois sinais de áudios de telhas com e sem defeito.



Fonte: próprio autor.

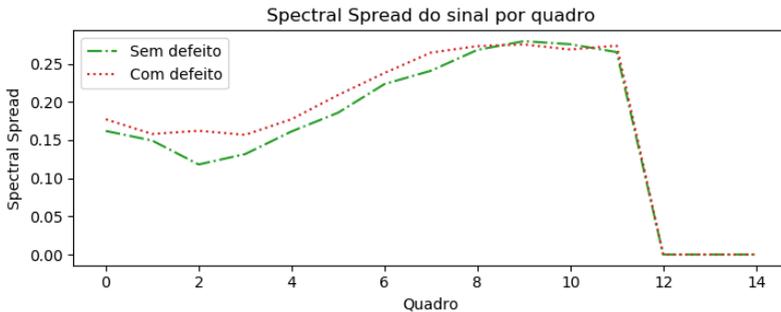
### 3.3.2.2 Spectral Spread

A característica *Spectral Spread* ou propagação espectral, pode ser definida como uma medida da forma espectral de um determinado segmento de sinal. Para Giannakopoulos (2014), a propagação espectral é o segundo momento central do espectro, conforme pode-se ver na Equação 3.13:

$$S_i = \sqrt{\frac{\sum_{k=1}^{W_{fL}} (k - C_i)^2 |X_i(k)|}{\sum_{k=1}^{W_{fL}} |X_i(k)|}} \quad (3.13)$$

A Figura 11 apresenta um exemplo do cálculo das centroides espectrais de dois sinais obtidos de amostras com e sem defeitos.

Figura 11 – *Spectral Spread* de dois sinais de áudios de telhas com e sem defeito.



Fonte: próprio autor.

### 3.3.2.3 Entropia espectral

De acordo com Misra et al. (2004), a entropia espectral pode ser calculada de forma similar a entropia do sinal, porém, desta vez no domínio da frequência. Novamente o espectro é dividido em  $L$  sub-bandas (bins). A energia  $E_f$  da *sub-banda* $_f$ ,  $f = 0, \dots, L - 1$ , é normalizada pela energia total do espectro, ou seja,  $n_f = \frac{E_f}{\sum_{f=0}^{L-1} E_f}$ . A entropia es-

pectral do quadro em análise pode ser então calculada de acordo com a Equação 3.14.

$$H(i) = - \sum_{f=0}^{L-1} n_f \times \log_2(n_f) \quad (3.14)$$

### 3.3.2.4 Fluxo espectral

O Fluxo espectral, também conhecido por *Spectral Flux*, pode ser entendido como uma medição da mudança espectral que ocorre entre dois quadros sucessivos e pode ser calculado como a diferença quadrática entre duas janelas consecutivas, conforme fica evidente na Equação 3.15:

$$Fl_{(i,i-1)} = \sum_{k=1}^{W_{fL}} (EN_i(k) - EN_{i-1}(k))^2, \quad (3.15)$$

### 3.3.2.5 Spectral Rolloff

O Spectral Rolloff ou a frequência roll-off diz respeito a frequência sob a qual um determinado percentual (*cutoff*) da distribuição de magnitude do espectro está contida (PEETERS, 2004). Conforme é detalhado em Giannakopoulos (2014), se o  $m$ -ésimo coeficiente da TDF corresponde ao *spectral rolloff* da  $i$ -ésima janela, então ele satisfaz a seguinte equação:

$$\sum_{k=1}^m |X_i(k)| = C \sum_{k=1}^{W_{fL}} |X_i(k)|, \quad (3.16)$$

onde  $C$  é o percentual adotado (*cutoff*). No presente estudo o *spectral rolloff* foi normalizado dividindo o mesmo por  $W_{fL}$ , de tal forma que tais valores assumissem apenas valores entre 0 e 1.

A característica *spectral rolloff* também pode ser tratada como um descritor da forma de um sinal de áudio. Em Theodoridis e Koutroubas (2008) e Kim, Moreau e Sikora (2005) os autores utilizam-se deste fato para fazer a discriminação entre sons que apresentam vozes e outros tipos de sons diversos. Ainda conforme os autores, esta característica também é frequentemente utilizada para identificar gêneros

musicais.

### 3.3.2.6 Mel-Frequency Cepstral Coefficients (MFCC)

Os denominados Mel-Frequency Cepstral Coefficients (MFCC) , são um tipo de representação cepstral de um determinado sinal. Os MFCCs são bem populares e amplamente utilizadas em sistemas onde faz-se necessário a interpretação de informações contidas em sinais de áudio, como por exemplo em sistemas de reconhecimento de fala (RABINER; SAMBUR, 1975), classificação de gêneros musicais (TZANETAKIS; COOK, 2002), clusterização de vozes (GIANNAKOPOULOS; PETRIDIS, 2010) entre outras aplicações.

Conforme é discutido em Gordillo (2013), a técnica de extração de MFCCs se baseia em uma análise das características espectrais de tempo curto, fazendo o uso do espectro do sinal convertido para uma escala de frequências denominada MEL. Ainda de acordo com o autor, a escala MEL visa imitar as características de áudio únicas que são percebidas pelo ouvido humano.

Na literatura existem algumas variações na implementação computacional de algoritmos que buscam extrair os coeficientes mel-cepstrais de um determinado espectro. Devido ao fato de que a descrição deste algoritmo é relativamente extensa e complexa, não será feita uma discussão aprofundada sobre os passos que levam a obtenção dos MFCCs. Para maiores informações sobre como é feita a extração e também para obter detalhes da implementação computacional do algoritmo pode-se consultar a explanação contida em Slaney (1998).

### 3.3.2.7 *Chroma vector e Chroma Deviation*

O *Chroma vector* é uma representação da energia espectral do sinal feita através de um vetor de 12 elementos (WAKEFIELD, 1999). Basicamente esta informação nos dá um artefato chamado "chromagram", ou em uma tradução livre "chromograma" que pode ser utilizada para caracterizar a distribuição de energia do sinal. De acordo com Wakefield (1999), depois dos MFCCs, o Chroma Vector é o descritor mais utilizado em aplicações relacionadas ao processamento de músicas em geral, como pode se ver em Bartsch e Wakefield (2005), Bartsch e Wakefield (2001) e Muller, Kurth e Clausen (2005). A Equação 3.17 define como é formado o vetor chroma de 12 elementos. Vale-se ressaltar que

$s_k$  é um sub-conjunto das frequências que correspondem aos coeficientes da DFT e  $n_k$  é a cardinalidade de  $s_k$ .

$$v_k = \sum_{n \in s_k} \frac{X_i(n)}{N_k} \quad (3.17)$$

Como o resultado do *Chroma vector* são 12 coeficientes, em Giannakopoulos (2014) propõe a criação de uma nova característica que é dada pelo desvio padrão desses 12 elementos. Para esta nova característica deu-se o nome de *Chroma Deviation*.

### 3.4 SELEÇÃO DE CARACTERÍSTICAS

Conforme já tratado anteriormente, uma característica (*feature*), pode ser definida como uma propriedade individual e mensurável do processo que está sendo observado. É a partir de conjuntos de características que os algoritmos de aprendizado de máquina conseguem fazer classificações. Deste modo, é de suma importância que as variáveis que descrevam determinados processos (características) estejam estruturadas de forma a contribuir positivamente nos modelos de inferências.

De acordo com Chandrashekar e Sahin (2014), nos últimos anos as aplicações de reconhecimento de padrões e aprendizado de máquina vem se tornando mais robustas e complexas, de tal forma que o domínio de características analisadas acabou aumentando significativamente de dezenas para centenas de variáveis observadas. Diversos fatores contribuem para este aumento no número de características, pois com o advento de novos sensores e tecnologias, assim como surgimento de bases de dados públicas e outros aspectos, o cientista de dados (profissional que realiza esse tipo de trabalho) possui muito mais informações para analisar e combinar, afim de se elaborar modelos de classificações, predições, clusterizações e entre outros.

No entanto, conforme é discutido em Cai et al. (2018), utilizar uma grande quantidade de informações não significa um modelo de classificação mais eficiente, uma vez que estes dados acabam sendo difíceis de se interpretar, dada suas amplas dimensões. Um outro ponto importante a se destacar é que essa grande quantidade de dados acaba tendo um impacto no desempenho do modelo e pode vir a se tornar um problema. É neste contexto que faz-se necessário o uso de alguma técnica de seleção de características.

Segundo Cai et al. (2018), seleção de características diz respeito ao processo de se obter um sub-conjunto de um conjunto original de

características, de acordo com algum critério de seleção. Ele é um processo de grande importância na etapa de pré-processamento de dados, haja vista que o mesmo retira da base de dados informações redundantes e/ou irrelevantes que poderiam acabar interferindo a classificação de forma negativa. A aplicação de técnicas de seleção de características pode impactar diversos aspectos de modelos de aprendizado de máquina, como por exemplo, melhorar a acurácia, reduzir o tempo de aprendizagem, e entre outros (LANGLEY, 1995).

Na literatura existem diversas técnicas de seleção de características que são utilizadas nos mais diversos tipos de aplicações. Em Chandrashekar e Sahin (2014) os autores destacam que existem três abordagens para se fazer essa seleção: filtragem, *embedded* e *wrapper*. Nas sub-seções abaixo serão tratados mais detalhes sobre cada abordagem destacada, porém, será dado mais enfoque aos métodos de filtragem, uma vez que no presente trabalho utilizou-se uma técnica de seleção de características considerada como uma técnica de filtragem.

### 3.4.1 Métodos de Filtragem

As técnicas baseadas em métodos de filtragem são fundamentadas na ideia de se fazer um *ranking* de importância das variáveis (características) disponíveis no *dataset*. De acordo com Chandrashekar e Sahin (2014), estes métodos de *ranking* são amplamente utilizados devido a sua simplicidade e sua eficácia em aplicações práticas. O propósito por trás desta abordagem consiste em se atribuir um peso (*score*) para cada característica, de acordo com algum critério escolhido, e na definição de um limite (*threshold*), de tal forma que as variáveis cujo *score* estiver abaixo do *threshold* definido devem ser eliminadas da base de dados.

As técnicas de seleção de características baseadas em "filtragem" recebem esta denominação pois elas são aplicadas antes de se fazer a classificação, fazendo assim um filtro e removendo as variáveis irrelevantes ou com baixa importância.

Conforme citado acima, para atribuir os pesos a cada uma das variáveis, ou seja, para identificar qual a importância da mesma para a distinção entre as diferentes classes existentes na base de dados, podem ser utilizadas algumas métricas. Algumas destas métricas, como o critério de correlação e o de informação mútua são discutidas e demonstradas em Chandrashekar e Sahin (2014) com mais detalhes.

### 3.4.2 Métodos *Wrapper*

Os métodos baseados em *wrapper* são considerados métodos de caixa preta, pois dado um conjunto de características  $E$ , fazem a predição de um sub-conjunto  $D$ , tal que  $D \subset E$ , e utilizam o erro de classificação ou a acurácia para avaliar se o sub-conjunto  $E$  foi uma boa seleção de características (CHANDRASHEKAR; SAHIN, 2014). De acordo com Cai et al. (2018), este tipo de seleção de características tende a produzir resultados com alta acurácia e um conjunto de características ótimas pequeno, porém, os modelos gerados possuem baixa capacidade de generalização e tempo computacional muito alto. É importante ressaltar que esse processo é feito de forma simultânea com a etapa de treinamento do modelo de classificação, ou seja, a etapa de aprendizagem do processo acaba tendo um grande custo computacional, tanto de tempo quanto de processamento.

### 3.4.3 Métodos *Embedded*

Os métodos *embedded* visam diminuir os custos computacionais e de tempo gastos na classificações de diferentes sub-conjuntos que são feitos nos métodos *wrapper*. O propósito deste tipo de abordagem é combinar o que há de melhor entre os outros dois métodos anteriores (filtragem e *wrapper*).

Um tipo de método *embedded* muito comum na literatura e implementado em diversas bibliotecas de *machine-learning* disponíveis no mercado é a técnica de seleção de características com o método LASSO - *Least Absolute Shrinkage and Selection Operator*, que será explanado com maiores detalhes na sub-seção 3.4.3.1.

#### 3.4.3.1 Seleção de características utilizando LASSO

LASSO - *Least Absolute Shrinkage and Selection Operator*, foi primeiramente formulado por Robert Tibshirani em 1996. Este método é um tipo de regressão de encolhimento, cujo objetivo é o de suavizar atributos similares entre si na base de dados, ou seja, busca diminuir o grau de colinearidade do conjunto de dados. O funcionamento do mesmo consiste em, basicamente, se colocar uma restrição na soma dos valores absolutos dos parâmetros do modelo analisado, de tal forma que essa soma não pode ser maior que um limite fixado (*upper bound*).

A partir disso, o método aplica um processo de regularização (muitas vezes chamado de encolhimento), onde ele penaliza os coeficientes da regressão, fazendo com que alguns acabem se reduzindo a zero (importante destacar que essa penalização é feita mais abruptamente para atributos com alto grau de correlação entre si). Desta maneira, para fazer a seleção de características, são escolhidas apenas as características cujos coeficientes da regressão não foram zerados (FONTI; BELITSER, 2017). O objetivo deste processo é minimizar o erro de predição do modelo. Não será aprofundado os detalhes deste método uma vez que tal explicação iria se estender muito. Maiores informações sobre o mesmo podem ser encontradas em Zhang, Guo e Edu (2016), Muthukrishnan e Rohini (2016) e Kamkar et al. (2015). É importante ressaltar que no presente trabalho utilizou-se a implementação do LASSO disponível no pacote *scikit-learn*, em Python, e que é amplamente discutida em Pedregosa et al. (2012).

## 4 APRENDIZADO DE MÁQUINA

Segundo Xin et al. (2018), aprendizado de máquina (*machine learning*) é um braço da inteligência artificial muito próximo da estatística computacional, que tem por objetivo fazer previsões utilizando computadores. As técnicas de aprendizado de máquina podem ser classificadas em duas categorias, de acordo com o tipo de aprendizagem. A primeira categoria diz respeito as técnicas de aprendizado supervisionado, onde inicialmente é separado um conjunto de dados de treinamento, previamente classificado (rotulado), que servirá como base de ensino para o modelo de previsão. Já a segunda categoria diz respeito as técnicas de aprendizado não-supervisionado, cujo foco está na separação (*clusterização*) de uma determinada base de dados, de forma autônoma, agrupando as observações similares. Como técnicas que utilizam aprendizado supervisionado pode-se citar *Linear Discriminant Analysis* (LDA), *K-Nearest Neighbors* - KNN, *Support Vector Machines* - SVM, *Naïve Bayes*, *Random Forest*, redes neurais artificiais entre outros. Em relação as técnicas de aprendizado não-supervisionado, é muito comum o uso da técnica *k-means clustering*.

No presente estudo optou-se por testar e avaliar alguns classificadores baseados em aprendizado supervisionado, que serão explanados e discutidos nas sub-seções seguintes.

### 4.1 ALGORITMOS DE CLASSIFICAÇÃO

Conforme discutido acima, existem diversos algoritmos de classificação na literatura, sendo que a acurácia dos mesmos pode variar dependendo de diversos fatores como o tamanho da base de dados, a disposição dos dados, a quantidade de classes existentes, parâmetros (configurações) do algoritmo entre outros.

Nas sub-seções abaixo serão discutidos três algoritmos que foram aplicados no presente estudo: *Linear Discriminant Analysis* (LDA), *K-Nearest Neighbors* (k-NN) e *Support Vector Machines* (SVM). A ideia de se aplicar três algoritmos diferentes foi para se avaliar o desempenho de cada um na classificação de telhas cerâmicas. A opção por escolher os três classificadores acima citados não seguiu nenhum critério específico.

### 4.1.1 *Linear Discriminant Analysis (LDA)*

A técnica *Linear Discriminant Analysis (LDA)*, também conhecida como *Fisher's Discriminant Analysis* é muito explorada e utilizada com frequência para se fazer classificações. Basicamente o LDA consiste no cálculo da variância entre as classes das observações analisadas. Em Altay (2018) o autor cita uma série de exemplos onde o LDA é utilizado para fazer redução de dimensão e classificações dos mais diversos tipos, como por exemplo, reconhecimento facial, reconhecimento de marcha corporal, extração de características entre outros.

Como esta análise compreende diversos cálculos matriciais (dispersões) dos vetores de observações, será suprido os detalhes matemáticos do algoritmo, sendo que maiores informações sobre o funcionamento do mesmo podem ser obtidos nos trabalhos de Al-anzi e AbuZeina (2017), Altay (2018) e Othman et al. (2017).

### 4.1.2 *K-Nearest Neighbors (k-NN)*

O k-NN (K – Nearest Neighbors) é um dos algoritmos de classificação mais populares em aplicações que envolvem aprendizado de máquina e mineração de dados. Esta popularidade se dá devido ao fato do mesmo ser relativamente simples e, geralmente, apresentar boa acurácia (S. et al., 2016) (FANG et al., 2008).

Pelo método de aprendizado supervisionado, o k-NN precisa de dois conjuntos de dados distintos: o conjunto de treinamento e o conjunto de testes. O conjunto de treinamento é composto por uma matriz  $M \times N$ , onde  $M$  é o número de observações e  $N$  é o número de características de cada entrada e um vetor de tamanho  $M$  que define qual a classe de cada uma das observações.

Basicamente o algoritmo é composto por três etapas principais que são:

1. Cálculo de distância;
2. Busca pelos vizinhos próximos;
3. Predição da classe.

**Cálculo de distância:** o cálculo de distância faz a medida de quão longe um dado vetor de testes está em relação aos  $M$  vetores de treinamento. Os métodos para o cálculo destas distâncias vectoriais

podem variar, porém, neste trabalho optou-se por utilizar a distância Euclideana. Dado dois vetores  $X$  e  $Y$  de tamanho  $n$ , a distância Euclideana  $D$  entre os mesmos é dada pela Equação 4.1.

$$D = \sqrt{\sum_{i=1}^n (X_i - Y_i)^2} \quad (4.1)$$

**Busca pelo vizinho mais próximo:** na etapa de busca pelos vizinhos próximos as distâncias obtidas na etapa anterior são ordenadas de forma crescente, identificando quais vetores de treino estão pertos do vetor de teste.

**Predição da classe:** na última etapa é feita uma análise de maioria e a classe que aparece de forma predominante nos  $k$ -primeiros vetores ordenados pela menor distância é definida como a classe do vetor de testes.

De acordo com Fang et al. (2008), o parâmetro  $k$  possui uma relação direta com a disposição dos dados do conjunto de treinamento.

### 4.1.3 Support Vector Machines (SVM)

O classificador SVM (Support Vector Machine), também conhecido como Máquina de vetores de suporte, é amplamente utilizado em diferentes tipos de problemas de classificação, como análise de risco de crédito, diagnóstico médico, categorização de textos entre outros. A técnica de classificação SVM, apesar de ser inicialmente projetada para fazer classificação binária, pode também ser utilizada em problemas multi-classes (DEMIDOVA et al., 2017).

O funcionamento do SVM se dá de tal maneira que dado um conjunto de treinamento, composto por uma matriz de observações e um vetor indicando a classe de cada observação, é feita uma separação no espaço entre essas observações, de acordo com a classe a qual cada uma pertence. Esta linha de separação também é conhecida como *hiperplano* e o objetivo da mesma é maximizar a distância entre os pontos mais próximos entre duas classes distintas.

No algoritmo SVM é possível definir alguns parâmetros que influenciam diretamente na acurácia do sistema. De acordo com Demidova e Klyueva (2017), o parâmetro que mais influência na classificação utilizando SVM é o tipo da função *kernel*. Similarmente ao que foi feito no caso do algoritmo k-NN, no presente estudo optou-se por variar a função *kernel* entre as seguintes opções:

- Linear (produto escalar);
- Sigmoid;
- Polinomial com ordem 3;
- RBF - Função de base radial Gaussiana;

## 4.2 OTIMIZAÇÃO DE PARÂMETROS

A grande maioria dos classificadores comumente utilizados na literatura possuem dois tipos de parâmetros que precisam ser definidos: o primeiro tipo diz respeito aos parâmetros de aprendizagem, já o segundo, diz respeito aos parâmetros de configurações, popularmente conhecidos como *hyperparameters*. Abaixo segue uma breve explicação sobre estes tipos, assim como alguns exemplos.

- Parâmetros de aprendizagem: os parâmetros de aprendizagem são definidos durante a etapa de aprendizagem e seus valores irão depender exclusivamente dos dados de treinamento. Um exemplo clássico deste tipo de parâmetros é os pesos dos neurônios de uma rede neural artificial, que são estipulados conforme os dados de treino;
- *Hyperparameters*: os *hyperparameters* são configurações ou propriedades específicas de cada classificador e não estão diretamente ligados com os dados de treinamento. Geralmente são definidos de forma empírica pelo usuário. Alguns exemplos desse tipo de parâmetros são o K (número de vizinhos) do K-NN, a função *kernel* do SVM, a quantidade de camadas intermediárias de uma rede neural e entre outros.

Diferentemente dos parâmetros de aprendizagem, que são definidos conforme o algoritmo de aprendizagem, os *hyperparameters* são definidos de forma empírica (pelo usuário) e impactam diretamente na qualidade do modelo de classificação. Tendo isto em vista, durante a etapa de escolha do classificador faz-se necessário encontrar os possíveis parâmetros de configuração ótimos (que geram os melhores resultados). Existem diversas técnicas que visam encontrar os melhores parâmetros para um dado classificador.

No presente estudo optou-se por utilizar o *Grid Search Algorithm* para se fazer esta otimização, em conjunto com a técnica de validação

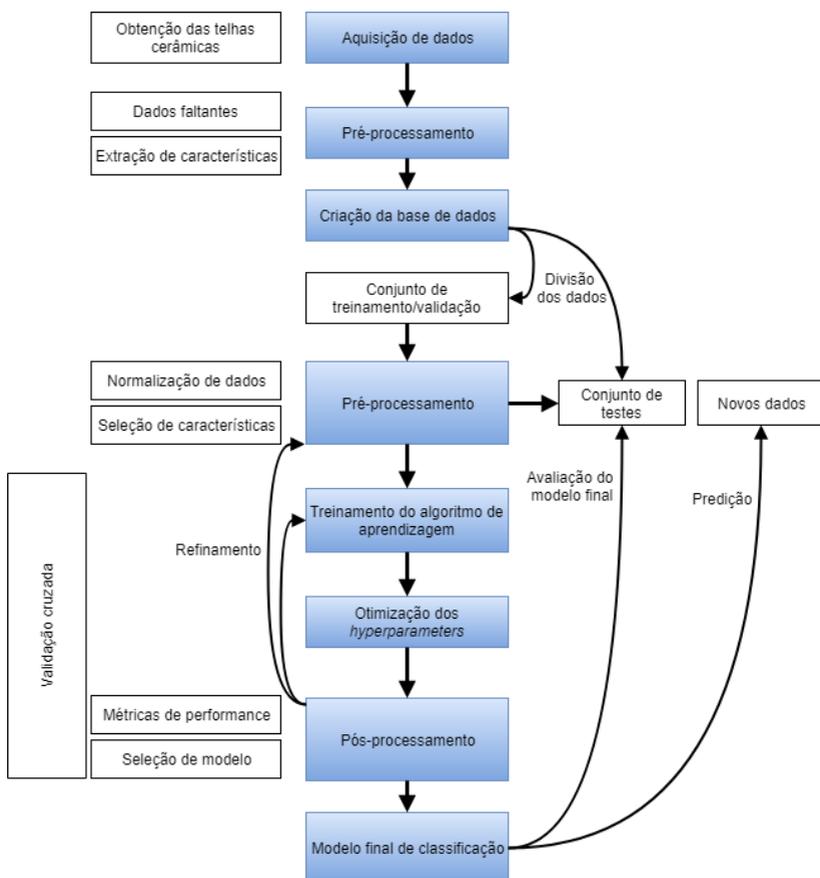
cruzada, cujo objetivo é o de evitar o *overfitting*. O funcionamento deste algoritmo de otimização é relativamente simples, se comparado com outras técnicas mais robustas como uso de algoritmos genéticos e similares, porém, sua eficácia geralmente apresenta bons resultados. Basicamente é apresentado para o algoritmo um espaço de busca, de tal forma que iterativamente o mesmo irá encontrar o (s) parâmetro (s) que otimizam determinada métrica (neste caso, a métrica utilizada foi a acurácia geral - *overall accuracy*). Maiores detalhes sobre o *Grid Search Algorithm* podem ser vistos nos trabalhos de Chih-Wei Hsu, Chih-Chung Chang e Lin (2008) e Kim, Krutchkoff e Terrell (1997).



## 5 IMPLEMENTAÇÃO DO SISTEMA

A implementação do sistema de classificação de telhas cerâmicas foi feita seguindo uma série de procedimentos, desde a obtenção das amostras de telhas até a avaliação dos modelos de classificação. A Figura 12 demonstra, de forma intuitiva, o fluxo de execução do projeto.

Figura 12 – Fluxo de execução do sistema de classificação de telhas cerâmicas



Fonte: próprio autor.

Um aspecto muito importante em um sistema cuja aplicação se daria em cima de uma linha de produção, é o quesito tempo de execução. As telhas cerâmicas são produzidas em série, sendo que todo o seu transporte pela linha de produção se dá por cima de esteiras. Como essas esteiras são tracionadas por motores a uma determinada rotação, o sistema de classificação como um todo precisa obedecer um requisito de tempo.

As etapas de seleção de características e treinamento do classificador seriam feitas de forma *off-line*, ou seja, fora da linha de produção, logo, estas não possuem a mesma restrição que a etapa de classificação (predição). Porém, para fins científicos, no presente estudo procurou-se mensurar o custo computacional de todas as etapas do processo. Abaixo seguem os processos que foram contabilizados:

- Tempo de execução do algoritmo de seleção de características;
- Tempo de execução do treinamento e refinamento de parâmetros de cada um dos classificadores;
- Tempo de execução do teste de cada um dos classificadores.

A máquina utilizada para se fazer estes testes de desempenho foi um *notebook* ASUS X550L, processador Intel Core i5 - 1.7GHz e 8GB de memória RAM, com sistema operacional Linux Mint 18.3 Cinnamon. As implementações dos algoritmos utilizados (em linguagem Python) são de autoria de Giannakopoulos (2014) e Pedregosa et al. (2011).

## 5.1 AMOSTRAS

No presente trabalho foram utilizadas telhas do tipo portuguesa. Este tipo de telha é comumente produzido na região sul-catarinense por cerâmicas de pequeno porte e que contam com pouco, as vezes nenhum, grau de automatização no processo produtivo. A Tabela 1 apresenta algumas especificações a respeito de telhas cerâmicas do tipo portuguesa, sendo que estes valores são apresentados em Falcão (2002).

As amostras foram obtidas através de parcerias com o SINDICER - Sindicato da Indústria da Cerâmica Vermelha, intermediadas pelo LPA - Laboratório de Pesquisa Aplicada, sendo este último um laboratório de pesquisa localizado na Universidade Federal de Santa Catarina - Campus Araranguá. O SINDICER, localizado em Morro da Fumaça - SC, é uma entidade representativa do setor cerâmico na

Tabela 1 – Especificações técnicas de telhas do tipo portuguesa

Peso	2.9 a 4.5 kg
Comprimento	40 a 48 cm
Largura	23 a 30 cm
Altura	5 a 9 cm

região, contando com mais de 150 empresas associadas. Dentre as atividades desenvolvidas pelo sindicato, destaca-se as assessorias nas áreas de engenharias, geologia, jurídica, lavra, laudos técnicos, ensaios de laboratório entre outras (SINDICER, 2018).

Os técnicos do SINDICER forneceram um total de 12 amostras de telhas do tipo portuguesa, fabricadas por uma cerâmica local. Destas amostras, 6 eram consideradas boas e as outras 6 restantes eram consideradas ruins (com algum tipo de defeito como descolamento, trinca, entre outros). Essa classificação foi feita previamente por técnicos com experiência na seleção de telhas cerâmicas do tipo analisado.

Conforme já citado anteriormente, as telhas utilizadas fazem parte do grupo de cerâmica vermelha, sendo que o estilo das mesmas é o estilo de telha portuguesa. A Figura 13 demonstra uma das peças analisadas.

## 5.2 AQUISIÇÃO DE DADOS

Nas visitas realizadas em cerâmicas da região do entorno de Criciúma - SC constatou-se que os funcionários responsáveis por detectar estes tipos de falhas utilizavam um martelo com ponta em *Technyl* para dar uma pancada não-destrutiva na estrutura arredondada da peça e analisar o som emitido pela mesma. Na Figura 14 pode-se ver em destaque a área na qual é feita a batida para identificar falhas estruturais em telhas cerâmicas.

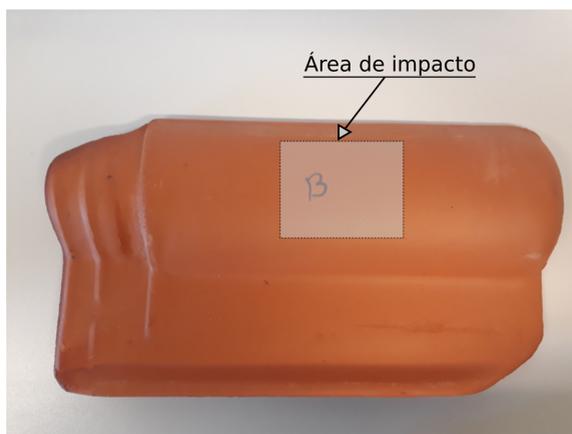
Desta forma, foi criada uma estrutura física em MDF (*Medium Density Fiberboard*), que ficava disposta por cima das telhas analisadas. No centro desta estrutura foi fixado um tubo de PVC (Policloreto de Polivinila) que age como uma espécie de "guia" para o pistão que se choca com a telha. O pistão utilizado foi usinado em *Technyl*, sendo que o diâmetro do mesmo era de 3cm e o comprimento era 7,5cm. É importante ressaltar que, visando manter um padrão nas batidas, durante a aquisição de dados o pistão foi solto em queda livre sempre da mesma altura, atingindo a telha sempre com a mesma intensidade.

Figura 13 – Amostra de telha portuguesa utilizada no experimento.



Fonte: próprio autor.

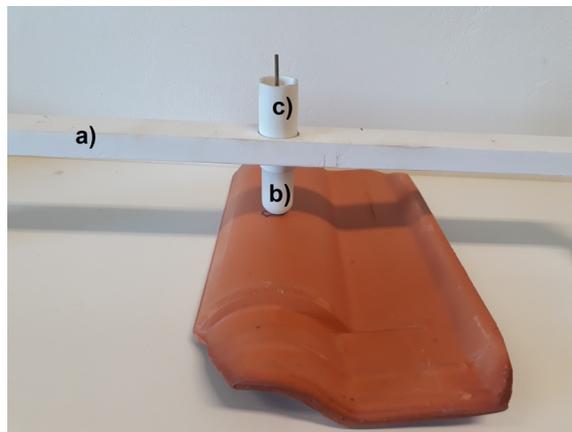
Figura 14 – Área de impacto do pistão na telha portuguesa.



Fonte: próprio autor.

Na Figura 15 pode-se ver a estrutura física construída em MDF, de tal maneira que tem-se em a) o local onde foi disposto o microfone para captação do áudio, em b) o pistão em *Technyl* e em c) o tubo de PVC que age como guia do pistão.

Figura 15 – Estrutura física em MDF e pistão de impacto.



Fonte: próprio autor.

Para se fazer a aquisição dos sinais de áudios (sons emitidos pela choque do pistão com as telhas) utilizou-se um microfone presente no *headset* Razer Kraken 7.1, conectado diretamente em um *notebook* convencional, através do software MATLAB, com uma taxa de amostragem de 44100Hz. Os sinais foram capturados em tempo real por um software desenvolvido pelo presente autor e, posteriormente, salvos em disco no formato WAV.

De acordo com o fabricante, a resposta de frequência do microfone utilizado é de 100Hz a 10kHz, com uma relação sinal-ruído superior a 55dB. Outro aspecto muito importante deste dispositivo é que o mesmo é do padrão polar unidirecional, e conta ainda com um sistema proprietário de cancelamento de ruído ativo. Conforme testes realizados durante esta etapa, viu-se que este sistema agregado no microfone busca identificar e atenuar o som ambiente constante, captando apenas sons que se diferenciam da normalidade.

### 5.3 CRIAÇÃO DA BASE DE DADOS

Uma das etapas mais importantes do presente trabalho é a criação da base de dados de áudios. Esta importância se dá devido ao fato de que todo o restante das tarefas (pré-processamento, janelamento, extração de características, seleção de características e classificação) depende de uma base de dados bem feita e fiel a realidade do processo que está se automatizando.

Para a criação da base de dados dispunha-se de um total de 12 amostras físicas de telhas cerâmicas do tipo portuguesa, sendo que destas, 50% estava em condições comerciáveis e 50% possuía algum tipo de defeito estrutural. Visando gerar uma base de dados grande suficiente para ser utilizada no sistema de classificação, cada telha disponível foi analisada diversas vezes, de tal de forma que criou-se um conjunto de dados contendo 280 amostras, sendo que destas, 140 eram oriundas de telhas consideradas boas e as 140 restantes eram de telhas com falhas estruturais internas.

Nesta etapa de criação da base de dados são executados dois processos: extração de características e identificação de dados faltantes. Os algoritmos utilizados para se fazer a extração de características garantem que para todas as situações analisadas, um valor numérico é retornado, independente da característica em questão. Desta forma, no presente trabalho não foi necessário adotar nenhuma estratégia para tratar casos de ausência de informações na base de dados. A sub-seção abaixo tratará detalhes sobre como foi feita a extração de características.

#### 5.3.1 Extração de características

Dada a natureza abstrata dos sinais de áudio, optou-se por extrair diversas características da base de dados, tanto características temporais (obtidas no domínio do tempo), como informações espectrais (obtidas no domínio da frequência).

A Tabela 2 apresenta um panorama geral sobre todas as características extraídas e os seus respectivos índices nas colunas da base de dados. Maiores detalhes sobre cada uma das características podem ser vistos na seção 3.3. É importante ressaltar que todas estas informações dispostas na tabela são extraídas no processamento de termo curto, ou seja, em cada um dos quadros do janelamento. Desta forma, para cada uma janela de termo curto, são extraídos 34 valores.

Tabela 2 – Especificações das características extraídas

	<b>Índice</b>	<b>Nome</b>
Temporais	1	<i>Zero Crossing Rate</i>
	2	Energia
	3	Entropia
Espectrais	4	Centróide espectral
	5	<i>Spectral Spread</i>
	6	Entropia espectral
	7	Fluxo espectral
	8	<i>Spectral Rolloff</i>
	9-21	MFCCs
	22-33	<i>Chroma Vector</i>
	34	<i>Chroma Deviation</i>

Como fica evidente na tabela, nem todas as características resultam em um único valor numérico. Os MFCCs e o *Chroma Vector* são formados por 13 e 12 coeficientes, respectivamente.

Como já foi discutido em seções anteriores, neste trabalho foi adotado uma metodologia de janelamento em duas etapas:

- Processamento de termo-curto: é executado o janelamento conforme o tamanho e o passo da janela (previamente definidos), sendo que para cada janela, são extraídos 34 valores (os valores dispostos na Tabela 2). Desta forma, para cada amostra analisada, será extraída uma matriz  $M \times N$ , onde  $M$  é a quantidade de características e  $N$  é o número total de quadros gerados no janelamento;
- Processamento de termo-médio: neste passo são calculados dados estatísticos dos resultados obtidos no processamento de termo-curto, visando reduzir a dimensão dos dados extraídos. Para cada uma das 34 características, são calculadas a média e o desvio padrão, logo, cada amostra analisada terá 68 colunas ( $N^{\circ}$  de características extraídas em termo curto  $\times N^{\circ}$  de estatísticas calculadas).

Para definir os tamanhos das janelas utilizadas (tanto no termo-curto quanto no termo médio), assim como os seus respectivos passos, optou-se por seguir as sugestões discutidas em Giannakopoulos (2014). A Tabela 3 apresenta os valores utilizados neste estudo.

Tabela 3 – Especificações dos parâmetros de janelamento

Descrição do parâmetro	Valor
Tamanho da janela de termo-curto	50ms
Passo (sobreposição) da janela de termo-curto	25ms
Tamanho da janela de termo-médio	500ms
Passo (sobreposição) da janela de termo-médio	0ms

Após a etapa de extração de características obteve-se uma matriz de tamanho  $280 \times 68$ , haja vista que foram analisadas 280 amostras e, para cada uma delas, obteve-se 68 características. Esta é a base de dados final que irá alimentar o processo de aprendizado de máquina.

### 5.3.2 Divisão da base de dados

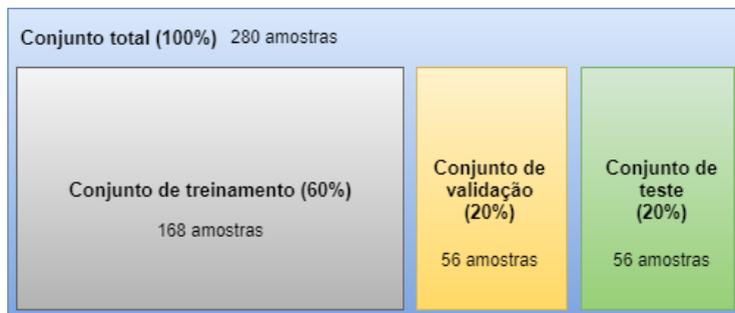
Em aplicações de aprendizado de máquina é muito comum a divisão da base de dados em dois conjuntos: treinamento e teste. A ideia é que os dados do conjunto de treinamento sejam utilizados no processo de aprendizagem do classificador escolhido. Uma vez que se tenha o modelo treinado, o classificador é alimentado com os dados do conjunto de testes afim de se avaliar algumas métricas do mesmo, como a acurácia (taxa de acerto), por exemplo.

Conforme foi discutido na Seção 4.2, em determinadas aplicações de aprendizado de máquina é feito a otimização dos *hyperparameters* do classificador. Nestes casos onde há esse processo de otimização, a divisão da base de dados precisa ser feita de outra forma, pois agora existem mais algumas etapas intermediárias, diferenciando-se do fluxo comum.

Sem entrar em muitos detalhes, o processo de otimização adotado neste trabalho consiste em se fazer a combinação de possíveis parâmetros, criar instâncias do classificador utilizando estes parâmetros, treinar os classificadores e em seguida, avaliar as suas acurácias. Esse processo é executado para uma série de combinações, de tal forma que o modelo ótimo é o que apresentou a melhor acurácia, conseqüentemente, este é o que possui a melhor combinação de parâmetros. Devido ao fato de existir essa avaliação da acurácia dos modelos durante a etapa de treinamento, é preciso separar o conjunto de treinamento em dois: um que será utilizado para treinar os classificadores (conjunto de treinamento) e outro para medir a acurácia dos classificadores (conjunto de validação). Por fim, após obter-se o classificador ideal, é feito o teste fi-

nal utilizando o conjunto de testes. A Figura 16 apresenta um diagrama de como fica a divisão final da base de dados.

Figura 16 – Diagrama da divisão final da base de dados.



Fonte: próprio autor.

#### 5.4 SELEÇÃO DE CARACTERÍSTICAS

Haja vista a grande quantidade de características existentes na base de dados (68), buscou-se aplicar uma técnica de redução de dimensão que não modificasse os dados da base, mas que apenas indicasse quais características possuem maior capacidade de discriminar entre telhas com falhas e telhas sem falhas.

Para este processo foi utilizado um algoritmo chamado LASSO, que foi comentado na Seção 3.4.3.1. A ideia básica por trás deste procedimento é selecionar um número  $N$  de características que sejam capazes de descrever e discriminar a base de dados. Nesta etapa o conjunto de treinamento (168 amostras) foi utilizado como base para que o algoritmo fosse capaz de identificar quais características deveriam ser selecionadas. Em seguida, toda a base de dados foi transformada, de modo que foram mantidas apenas as características resultantes do processo de seleção acima discutido.

O algoritmo LASSO possui uma série de parâmetros que irão impactar diretamente no número  $N$  de características que serão selecionadas. No presente estudo optou-se por utilizar a implementação do LASSO disposta na biblioteca *Scikit-Learn*, sendo que os valores dos parâmetros foram mantidos pelos valores padrões da biblioteca, definidos por Pedregosa et al. (2011).

## 5.5 SELEÇÃO DO MODELO DE CLASSIFICAÇÃO

A etapa de seleção do modelo de classificação consistiu na utilização dos conjuntos de treinamento e de validação para se testar e avaliar 3 classificadores: K-NN, SVM e LDA. Nestes testes foram utilizadas diferentes combinações de configurações (parâmetros) dos classificadores, afim de se obter o modelo com a melhor acurácia possível para resolver este problema.

Conforme foi discutido anteriormente, utilizou-se a técnica de validação cruzada chamada *K-Fold Cross-Validation* para se certificar de que o classificador não encontrou um máximo local. De acordo com Wong e Yang (2017), para cada uma combinação possível de parâmetros encontrada pelo *Grid Search Algorithm*, os passos abaixo são executados afim de medir a taxa de acerto do classificador:

1. Os conjuntos de treinamento e validação são unidos, formando um conjunto único contendo 224 amostras;
2. Divide-se em este novo conjunto em  $K$  *folds* (grupos menores). No presente trabalho utilizou-se  $K = 4$ , ou seja, foram formados 4 grupos menores, cada um com  $\frac{224}{4} = 56$  amostras;
3. É formado um grupo para treinar o classificador, utilizando os *folds* 1, 2 e 3. Já o *fold* 4 é utilizado como validação para se medir a acurácia (taxa de acerto) desta iteração.
4. O item 3 é repetido até que todos os *folds* sejam utilizados ao menos uma vez como grupo de validação.
5. A acurácia final do classificador é dada pela média aritmética das acurácias medidas ao longo das iterações.

É importante ressaltar que nesta etapa do processo em momento algum os dados do conjunto de testes são utilizados, haja vista que este conjunto deve ser utilizado somente após se encontrar o melhor modelo de classificação. Em teoria, o modelo selecionado deve possuir capacidade de generalização, logo, ele deve apresentar bons resultados quando aplicado ao conjunto de teste final.

Como já mencionado anteriormente, foram testados três classificadores diferentes, sendo que cada um destes algoritmos possuem parâmetros para serem configurados. A Tabela 4 apresenta quais parâmetros foram variados em cada algoritmo, durante o processo de seleção do melhor modelo.

Tabela 4 – *Hyperparameters* dos classificadores K-NN, SVM e LDA.

<b>Classificador</b>	<b>Parâmetros</b>	<b>Valores</b>
K-NN	Número de vizinhos (K)	2, 5, 10, 20, 50 e 100
LDA	<i>Solver</i>	SVD (decomposição de valor singular), LQSR (solução de mínimos quadráticos) e Eigen (decomposição de autovalores)
SVM	<i>Kernel</i>	Linear, RBF (função de base radial), Polynomial e Sigmoid
	Penalidade (C)	1, 10, 100 e 1000
	<i>Gamma</i>	0.001, 0.01, 0.1 e 1

A partir da operação de refinamento de parâmetros, realizada utilizando *K-Fold Cross Validation*, foi possível obter os melhores parâmetros (dentre os dispostos na Tabela 4) para cada um dos três classificadores testados.

A última etapa compreendida no escopo deste sistema consistiu em se avaliar os três melhores modelos de classificação utilizando o conjunto de testes, conjunto este que é composto por 56 amostras que até então não haviam sido utilizadas em nenhuma parte dos processos anteriores. A ideia desta avaliação final é verificar se os modelos selecionados realmente condizem com a realidade e se estes são capazes de classificar amostras desconhecidas.



## 6 RESULTADOS

Neste capítulo serão apresentados os resultados obtidos em cada uma das etapas descritas no Capítulo 5, assim como uma discussão sobre os valores encontrados. Inicialmente será tratado sobre quais características que foram escolhidas para melhor discriminar os dados, em seguida serão discutidos sobre quais parâmetros resultaram nos melhores modelos de classificação e, por fim, será apresentado os resultados dos melhores classificadores no conjunto de testes.

### 6.1 SELEÇÃO DE CARACTERÍSTICAS

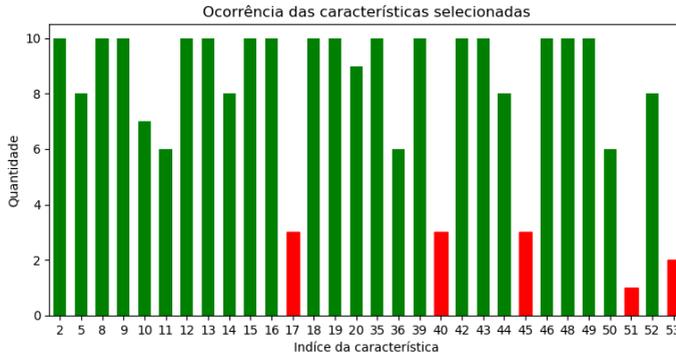
Como já foi discutido em capítulos anteriores, para a seleção de características utilizou-se o método LASSO. Método este que visa diminuir a dimensão da base de dados selecionando as características com maior importância discriminatória em relação a um determinado rótulo (neste estudo o rótulo é um valor binário indicando a existência ou não de falhas na amostra).

O algoritmo LASSO foi executado 10 vezes, sendo que em cada uma das iterações eram escolhidas aleatoriamente 224 amostras da base de dados (80% do total). O objetivo destas repetições foi o de averiguar se existia um padrão entre as características escolhidas em cada uma destas iterações.

A Figura 17 apresenta um histograma deste processo, onde é possível verificar quantas vezes determinada característica foi selecionada para discriminar a base de dados. Para facilitar a visualização do gráfico foi utilizado o ID (índice) da característica, ao invés do nome da mesma. Na Tabela 5 é possível visualizar a relação entre estes índices e os nomes das respectivas características.

Conforme pode-se ver na Figura 17, existem algumas colunas destacadas (17, 40, 45, 51 e 53). Estas colunas destacadas representam as características que foram selecionadas pelo LASSO em alguma das iterações, porém, as mesmas foram descartadas, uma vez que a frequência delas neste processo iterativo ficou abaixo do limite (*threshold*) definido de forma empírica pelo presente autor. Neste caso em específico, utilizou-se um limite de 5, ou seja, foram escolhidas somente as características que apareceram mais de 5 vezes nas 10 repetições realizadas. Desta forma, o conjunto de características que melhor representa a base de dados é composto por 25 características.

Figura 17 – Frequência de seleção das características.



Fonte: próprio autor.

Na Tabela 5 os itens sinalizadas com um asterisco (\*) dizem respeito as características que não foram consideradas na seleção final.

Tabela 5 – Relação das características selecionadas

ID	Característica	ID	Característica
2	Entropia (média)	35	Energia (std)
5	Entropia espectral (média)	36	Entropia (std)
8	MFCC 1 (média)	39	Entropia espectral (std)
9	MFCC 2 (média)	40	*Fluxo espectral (std)
10	MFCC 3 (média)	42	MFCC 1 (std)
11	MFCC 4 (média)	43	MFCC 2 (std)
12	MFCC 5 (média)	44	MFCC 3 (std)
13	MFCC 6 (média)	45	*MFCC 4 (std)
14	MFCC 7 (média)	46	MFCC 5 (std)
15	MFCC 8 (média)	48	MFCC 7 (std)
16	MFCC 9 (média)	49	MFCC 8 (std)
17	*MFCC 10 (média)	50	MFCC 9 (std)
18	MFCC 11 (média)	51	*MFCC 10 (std)
19	MFCC 12 (média)	52	MFCC 11 (std)
20	MFCC 13 (média)	53	*MFCC 12 (std)

Analisando o resultado do processo de seleção de características viu-se que há uma dominância de características espectrais. Para ser mais exato, dos 25 descritores selecionados, apenas 3 (12%) são temporais, já os outros 22 (88%) foram extraídos no domínio da frequência. Em relação ao tipo de estatística extraída dessas características, houve um equilíbrio entre média e desvio padrão. Do total de 25 características, 14 (56%) são valores médios e as outras 11 (44%) restantes são desvios padrão.

Outro aspecto que foi mensurado nessa etapa de seleção de características foi o tempo necessário para que o algoritmo LASSO elencasse os descritores mais importantes. Para cada uma das 10 iterações, foi medido o tempo computacional para o algoritmo selecionar aleatoriamente os dados e realizar a seleção de características. O tempo médio gasto para executar esta operação foi de  $0.09964 \pm 0.00425$  segundos. Pode-se ver que o desvio padrão dos tempos mensurados é relativamente baixo, isso significa que os tempos medidos estão, no geral, próximo da média.

## 6.2 SELEÇÃO DOS MODELOS DE CLASSIFICAÇÃO

A seleção de modelos consistiu em se avaliar o desempenho dos três algoritmos propostos (LDA, K-NN e SVM), variando seus parâmetros, afim de se escolher os modelos (um de cada tipo) que apresentassem o melhor desempenho (acurácia). Conforme explanado em capítulos anteriores, nesta etapa foram utilizados um total de 224 amostras (conjuntos de treinamento e validação), que representam 80% do total de amostras da base de dados.

Afim de se obter uma comparação do impacto do processo de seleção de características nos resultados finais, toda esta etapa de seleção dos parâmetros dos classificadores foram feitas primeiramente utilizando todas as características da base (um total de 68) e depois o processo foi repetido, utilizando somente as 25 características selecionadas e apresentadas na Seção 6.1.

Para cada um dos três classificadores, o processo faz a combinação dos parâmetros (descritos pela Tabela 4), sendo que para cada combinação, um processo de validação *K-Fold Cross Validation* é executado, com  $K = 4$ . Desta forma, uma dada combinação de parâmetros é avaliada 4 vezes, sendo que em cada avaliação os dados são rotacionados e no fim é calculado a acurácia média e o desvio padrão das mesmas. No término da operação, para cada uma destas combinações

de parâmetros tem-se os seguintes dados:

- Acurácia média (dos *folds*);
- Desvio padrão das acurácias;
- Conjunto de parâmetros da combinação;
- Tempo necessário para testar a combinação.

De acordo com Pedregosa et al. (2011), o processo de otimização dos parâmetros dos classificadores (neste caso o *Grid Search*) deve adotar alguma medida de pontuação/avaliação, ou seja, ele deve otimizar o classificador visando maximizar/minimizar esta determinada métrica. Existem uma série de métricas que podem ser utilizadas para este fim, como por exemplo, a acurácia, a precisão média, o F-Score, *recall* entre outras. No presente estudo optou-se por otimizar os classificadores visando maximizar a acurácia.

A acurácia é uma medida que indica a fração de predições corretas em determinada operação de classificação. Dado que  $\hat{y}$  seja o valor predito da  $i$ -ésima amostra e que  $y_i$  seja o valor verdadeiro (real) correspondente, então a fração das predições corretas (acurácia) das  $n_{amostras}$  é definida pela Equação 6.1:

$$acuracia(y, \hat{y}) = \frac{1}{n_{amostras}} \sum_{i=0}^{n_{amostras}-1} 1(\hat{y}_i = y_i) \quad (6.1)$$

Analisando a Equação 6.1, tem-se que a acurácia de uma determinada predição será igual a 1.0 se todas as predições feitas estiverem corretas e 0.0 caso não houver nenhuma predição certa.

Haja vista o que algoritmo *Grid Search* irá testar todas combinações possíveis entre os parâmetros, a quantidade de testes realizados crescerá de acordo com o número de parâmetros utilizados e com a quantidade de valores possíveis para cada parâmetro.

Para o algoritmo SVM tem-se 3 parâmetros, que são o *kernel* (4 possíveis valores), a penalidade (4 possíveis valores) e o *gamma* (4 possíveis valores). Como cada um dos três parâmetros pode assumir 4 valores distintos, o número total de testes realizados afim de se encontrar o melhor modelo será  $4 \times 4 \times 4 = 64$ .

As Tabelas 6 e 7 apresentam os resultados da seleção do modelo para o classificador SVM, com e sem o processo de seleção de característica, respectivamente. Haja vista que a quantidade de possíveis combinações de parâmetros para o SVM é relativamente alta (64), optou-se por exibir apenas os cinco melhores resultados para cada situação.

Tabela 6 – Resultados - Seleção de parâmetros do classificador SVM (sem seleção de características)

<b>Kernel</b>	<b>C</b>	<b>Gamma</b>	<b>Acurácia</b>	<b>Tempo</b>
Linear	100.00	0.010	1.00 ± 0.00	0.60ms
RBF	100.00	0.010	1.00 ± 0.00	0.68ms
Poly	100.00	0.010	1.00 ± 0.00	0.87ms
Linear	100.00	0.100	1.00 ± 0.00	0.58ms
Poly	100.00	0.100	1.00 ± 0.00	0.85ms
Tempo total (64 combinações)				39.19ms

Tabela 7 – Resultados - Seleção de parâmetros do classificador SVM (com seleção de características)

<b>Kernel</b>	<b>C</b>	<b>Gamma</b>	<b>Acurácia</b>	<b>Tempo</b>
Linear	100.00	0.010	1.00 ± 0.00	0.49ms
RBF	100.00	0.010	1.00 ± 0.00	0.50ms
Poly	100.00	0.010	1.00 ± 0.00	0.85ms
Linear	100.00	0.100	1.00 ± 0.00	0.57ms
Poly	100.00	0.100	1.00 ± 0.00	0.90ms
Tempo total (64 combinações)				26.38ms

Como pode-se ver nas Tabelas 6 e 7, houve unanimidade em relação aos parâmetros que apresentam a melhor acurácia média (Kernel Linear,  $C = 100$  e  $\text{Gamma} = 0.010$ ). Um outro ponto curioso é o fato de que o SVM obteve as acurácias máximas em todos os casos, durante a etapa de refinamento de parâmetros. Comparando os dados destas duas tabelas também é possível identificar que o processo de seleção de características só impactou no tempo computacional necessário para se obter o melhor modelo (para ser mais específico, houve uma redução de 32,7% no tempo necessário).

Nas Tabelas 8 e 9 pode-se ver os resultados relacionados aos testes realizados no classificador K-NN. Tem-se um total de 6 possíveis combinações de parâmetros, uma vez que para este classificador específico foram testados 6 possíveis valores de  $K$  (número de vizinhos).

Tabela 8 – Resultados - Seleção de parâmetros do classificador K-NN (sem seleção de características)

<b>K</b>	<b>Acurácia</b>	<b>Tempo</b>
2.0	$0.95 \pm 0.05$	0.25ms
5.0	$0.92 \pm 0.03$	0.16ms
10.0	$0.88 \pm 0.05$	0.18ms
20.0	$0.82 \pm 0.10$	0.18ms
50.0	$0.75 \pm 0.06$	0.21ms
100.0	$0.73 \pm 0.11$	0.17ms
Tempo total		1.15ms

Tabela 9 – Resultados - Seleção de parâmetros do classificador K-NN (com seleção de características)

<b>K</b>	<b>Acurácia</b>	<b>Tempo</b>
2.0	$0.95 \pm 0.06$	0.14ms
5.0	$0.92 \pm 0.03$	0.13ms
10.0	$0.88 \pm 0.06$	0.19ms
20.0	$0.82 \pm 0.10$	0.13ms
50.0	$0.74 \pm 0.06$	0.22ms
100.0	$0.73 \pm 0.11$	0.16ms
Tempo total		0.97ms

A partir dos dados dispostos nas Tabelas 8 e 9 percebe-se que o número de vizinhos  $K = 2$  resultou na melhor acurácia média para as duas situações propostas (com e sem seleção de características). Similar ao que se viu no caso do SVM, no caso do K-NN o processo de seleção de características contribuiu significativamente para a melhora no tempo computacional de processamento, praticamente para todos os valores de  $K$ . No total, houve uma redução de aproximadamente 15% de tempo computacional.

Nas Tabelas 10 e 11 pode-se ver os resultados relacionados aos testes realizados no classificador LDA. Neste classificador o parâmetro *solver* foi variado entre três possíveis opções: Eigen, SVD e LSQR.

Os dados referentes aos resultados da seleção de parâmetros para o LDA apontaram algo que não havia acontecido nos outros classificadores: a acurácia média teve um leve incremento após se fazer o processo de seleção de características. Novamente o tempo computacional diminui nos testes em que se utilizou menos características (uma redução de

Tabela 10 – Resultados - Seleção de parâmetros do classificador LDA (sem seleção de características)

<i><b>Solver</b></i>	<i><b>Acurácia</b></i>	<i><b>Tempo</b></i>
LSQR	$0.99 \pm 0.02$	0.30ms
SVD	$0.99 \pm 0.02$	0.46ms
Eigen	$0.54 \pm 0.01$	0.20ms
Tempo total		0.96ms

Tabela 11 – Resultados - Seleção de parâmetros do classificador LDA (com seleção de características)

<i><b>Solver</b></i>	<i><b>Acurácia</b></i>	<i><b>Tempo</b></i>
LSQR	$1.00 \pm 0.02$	0.19ms
SVD	$1.00 \pm 0.02$	0.29ms
Eigen	$0.54 \pm 0.01$	0.19ms
Tempo total		0.67ms

aproximadamente 30,2%). Para o caso do LDA o *solver* que apresentou os melhores resultados foi o LSQR.

É importante destacar que os resultados demonstrados acima ainda não são a avaliação final dos classificadores. O objetivo desta etapa foi selecionar o melhor conjunto de parâmetros para cada classificador para então se fazer uma avaliação final, utilizando o conjunto de testes, que até então não foi utilizado em momento algum e que conta com 56 amostras (20% da base de dados total). Porém, nesta etapa de seleção dos modelos de classificação, ficou evidente que o classificador SVM foi o mais sensível ao processo de seleção de características, no que diz respeito ao custo computacional, ou seja, foi o que obteve a maior redução de custo computacional após se fazer a redução da base de dados.

### 6.3 AVALIAÇÃO DOS MODELOS DE CLASSIFICAÇÃO

Nesta seção serão apresentados os resultados finais da avaliação dos três melhores modelos de classificação selecionados na etapa anterior. A avaliação final será feita com os dados do conjunto de testes, que até então não foram utilizados em momento algum. Este teste final visa avaliar se os modelos de classificação previamente escolhidos são capazes de manter seus bons resultados em dados desconhecidos, ou

seja, verificar se tais modelos obtiveram a capacidade de generalização.

Diferentemente da etapa anterior onde os classificadores eram testados afim de se encontrar uma boa combinação de parâmetros, nesta etapa a ideia é apenas alimentar os modelos previamente selecionados com os dados de testes afim de se obter algumas métricas estatísticas sobre o desempenho dos classificadores. Na Seção 6.2 foi apresentado a acurácia média e o desvio padrão de cada processo de validação cruzada. Já nesta avaliação final, além da acurácia, serão exploradas e discutidas outras métricas capazes de descrever o comportamento dos classificadores.

Uma métrica comumente utilizada em aplicações de classificação binária e/ou *multi-label* é a matriz de confusão. Em classificações binárias, que é o caso do presente estudo, esta matriz é uma forma simples de se interpretar o desempenho das predições do classificador, além de que a partir da mesma é possível extrair algumas outras métricas. A Tabela 12 demonstra o exemplo de uma matriz de confusão para classificação binária, sendo que B representa uma amostra "Boa" e R uma amostra com defeito. TP diz respeito a quantidade de verdadeiro positivo, FP falso positivo, FN falso negativo e TN verdadeiro negativo.

Tabela 12 – Matriz de confusão para classificação binária

		Predição	
		R	B
Valor Real	R	TP	FP
	B	FN	TN

A partir da Tabela 12 é possível obter a acurácia geral, que diz respeito a taxa de predições corretas (acertos) e é definida por *OA*. Na literatura também pode-se encontrar esta métrica definida como *overall accuracy* ou precisão geral. A mesma é calculada através da Equação 6.2, conforme segue abaixo:

$$OA = \frac{TP + TN}{TP + TN + FP + FN} \quad (6.2)$$

Outras duas estatísticas que podem ser analisadas é a precisão (*precision*), que indica a habilidade do modelo em não classificar como positiva uma amostra negativa, e a revocação (*recall*), que é a habilidade do modelo em encontrar todas as amostras positivas. A precisão e a revocação podem ser calculadas através das Equações 6.3 e 6.4, respectivamente.

$$precision = \frac{TP}{TP + FP} \quad (6.3)$$

$$recall = \frac{TP}{TP + FN} \quad (6.4)$$

Para simplificar o entendimento destas medidas, suponha um motor de pesquisa que retorna para o usuário 30 páginas, porém, apenas 20 são relevantes, sendo que o mesmo deixa de exibir outras 40 que seriam relevantes. Nesta situação hipotética, a precisão do sistema é  $\frac{20}{30} = \frac{2}{3}$ , enquanto a revocação é  $\frac{20}{60} = \frac{1}{3}$ . Tanto o *recall* quanto a precisão devem ser analisados em conjunto, de acordo com a necessidade da aplicação.

Trazendo para a realidade do caso da classificação de telhas cerâmicas, suponha que determinada linha de produção deseja manter um controle de qualidade extremamente rígido, de tal forma que todas telhas ruins devem ser descartadas. Nesta situação, é interessante que se tenha uma precisão muito próxima ou igual a 1, mesmo que para isso não se tenha um *recall* alto (algumas telhas boas podem ser descartadas erroneamente).

Nas sub-seções seguintes serão apresentadas, primeiramente, as matrizes de confusão de cada um dos três melhores classificadores e, em seguida, na Tabela 16, um resumo com todas métricas calculadas nas avaliações finais dos modelos. Haja vista que foi realizado um processo de seleção de características, para fins de comparação serão apresentados os resultados da avaliação dos modelos com e sem a seleção de características.

É importante destacar que a operação que dividiu a base de dados nos conjuntos de treinamento, validação e testes acabou gerando um conjunto de testes composto por 56 amostras, sendo 37 boas e 19 ruins.

### 6.3.1 Matrizes de confusão

Para cada um dos três melhores classificadores selecionados foram montadas duas matrizes de confusão, uma para a avaliação do modelo sem fazer a seleção de características e outra para a avaliação fazendo o uso do processo de redução de características.

A Tabela 13 apresenta as matrizes de confusão referentes ao processo de avaliação do classificador SVM. Sem seleção significa que não foi aplicado o processo de seleção de características (utilizou-se todas

os 68 descritores disponíveis) e com seleção significa que o espaço de características foi reduzido para 25, conforme discutido em seções anteriores.

Tabela 13 – Matrizes de confusão da avaliação do classificador SVM

Sem seleção				Com seleção			
		Predição				Predição	
		R	B			R	B
Valor	R	19	0	Valor	R	19	0
Real	B	1	36	Real	B	1	36

Analisando as duas matrizes de confusão relacionadas ao SVM, é possível afirmar que o processo de seleção de características não impactou na acurácia geral do sistema, uma vez que ambas matrizes são idênticas. Em ambos os casos houve apenas uma classificação incorreta, que foi um falso negativo, onde uma telha considerada boa foi classificada como ruim.

Já na Tabela 14 pode-se ver as duas matrizes de confusão do classificador K-NN com  $K = 2$ .

Tabela 14 – Matrizes de confusão da avaliação do classificador K-NN

Sem seleção				Com seleção			
		Predição				Predição	
		R	B			R	B
Valor	R	19	0	Valor	R	19	0
Real	B	2	35	Real	B	3	34

Os resultados do classificador K-NN já apresentam alguns aspectos diferentes do que foi visto no SVM. Primeiramente, devido a existência de mais falsos negativos, fica evidente que a acurácia geral deste classificador será menor do que o classificador testado anteriormente. Comparando os dois testes realizados (com e sem seleção de características), percebe-se que após a eliminação de algumas características da base, o sistema passou a errar mais (após o processo de seleção de características houveram 3 falsos negativos).

A Tabela 15 apresenta as matrizes de confusão para o classificador LDA, sendo que de acordo com a etapa de seleção do melhor modelo, o *solver* escolhido foi o método LQSR.

Tabela 15 – Matrizes de confusão da avaliação do classificador LDA

		Sem seleção				Com seleção	
		Predição				Predição	
		R	B			R	B
Valor	R	19	0	Valor	R	19	0
Real	B	0	37	Real	B	1	36

O caso do LDA apresentou um resultado muito interessante e importante para o trabalho como um todo. Sem realizar a seleção de características este classificador foi capaz de fazer a classificação do conjunto de testes com 100% de acurácia, ou seja, acertou todos os casos existentes. No LDA, após o processo de redução do espaço de características, também houve um deterioramento da acurácia geral (o sistema passou a classificar uma telha normal como uma amostra defeituosa).

### 6.3.2 Métricas gerais da avaliação dos classificadores

Foi discutido anteriormente a existência de algumas métricas que podem ser calculadas a partir da matriz de confusão de um determinado processo de classificação binário. Seguindo a mesma metodologia que vem sendo adotada no decorrer deste trabalho, estas métricas foram calculadas para as avaliações realizadas com e sem o processo de seleção de características.

A Tabela 16 apresenta todas estas métricas (acurácia, precisão, *recall*), além do tempo (em milissegundos) necessário para se classificar todas as 56 amostras do conjunto de testes. A sigla SSC, na tabela, significa "Sem seleção de características", já CSC é "Com seleção de características".

Tabela 16 – Métricas gerais da avaliação dos classificadores

Métricas	SVM		K-NN		LDA	
	SSC	CSC	SSC	CSC	SSC	CSC
Acurácia	0.98	0.98	0.96	0.94	1.00	0.98
Precisão	1.00	1.00	1.00	1.00	1.00	1.00
Recall	0.97	0.97	0.95	0.92	1.00	0.97
Tempo (ms)	0.47	0.39	0.21	0.13	0.79	0.70

Para se ter uma melhor compreensão dos resultados da avaliação

dos melhores modelos, as matrizes de confusão e a Tabela 16 devem ser analisadas em conjunto. Fica claro que a existência de falsos negativos em alguns casos está impactando diretamente no *recall* e na acurácia geral destas classificações errôneas.

A partir da análise dos dados percebe-se que no geral todos os classificadores apresentaram acurácias muito boas, todas superiores a 90%. Também é possível visualizar que em todos os casos testados os modelos conseguiram ter uma precisão de 100%, ou seja, em nenhum teste uma telha com defeito foi considerada como uma amostra normal.

O LDA apresentou a melhor acurácia na bateria de testes, chegando a acertar 100% das predições sem utilizar o processo de seleção de características. Em contrapartida, percebe-se que o tempo computacional deste classificador é muito mais alto do que os outros (SVM e K-NN). Desta maneira, fica evidente a existência de um determinado *trade-off* entre escolher um modelo com alta acurácia ou um modelo com tempo de execução mais performático. Este *trade-off* fica a critério do cientista de dados responsável pela classificação, conforme a necessidade da aplicação.

O K-NN apresentou o melhor desempenho no quesito tempo de execução, tanto na etapa de refinamento de parâmetros como na etapa de testes. Porém, o mesmo acabou fazendo algumas predições incorretas, acarretando em uma acurácia mais baixa do que os demais modelos.

O SVM, de acordo com os resultados obtidos, foi um modelo que pode ser considerado como intermediário, pois acertou quase todos os casos, errando em apenas uma amostra, em um tempo de execução que ficou entre os máximos (LDA) e os mínimos (K-NN).

Analisando as matrizes de confusão, percebe-se que os erros de predição se concentram, geralmente, em falsos negativos. Haja vista a recorrência deste resultado, foi feita uma análise com o objetivo de verificar se os erros ocorridos foram para uma amostra específica. A análise mostrou que não, as amostras classificadas incorretamente foram distintas. Caso a mesma amostra tivesse sido classificada de forma errônea pelos diferentes classificadores, poderia ficar evidente a existência de possíveis *outliers*. *Outliers* são dados atípicos (ou aberrantes), que se distanciam muito da média (de um determinado grupo) como um todo e que acabam impactando negativamente na performance de modelos de classificação, uma vez que irão agregar ao modelo determinada tendência que não condiz com a realidade.



## 7 CONCLUSÃO

Os resultados obtidos no presente estudo mostraram que é possível caracterizar a qualidade estrutural de telhas cerâmicas fazendo o uso de processamento digital de sinais em conjunto com técnicas de aprendizado de máquina. A existência ou não de trincas, descolamentos, rachaduras e entre outros defeitos impactam diretamente no som produzido pela telha, após sofrer uma leve pancada não-destrutiva. Este impacto fica evidente na própria análise dos gráficos de algumas das características extraídas, onde é possível visualizar uma diferenciação de comportamento (dos sinais) entre amostras normais e amostras defeituosas.

O processo de seleção de características mostrou que, mesmo contendo um grande número de descritores na base de dados, apenas um conjunto menor de características realmente influenciaram no momento de discriminar as classes existentes (com falhas/sem falhas). É importante destacar também que este grupo menor foi composto predominantemente por características espectrais (obtidas em uma análise de frequência). Outro impacto observado foi que a diminuição do número de características reduziu consideravelmente o tempo computacional necessário para executar tanto as etapas de treinamento/refinamento de parâmetros quanto a etapa final de avaliação dos modelos.

Em relação ao processo de classificação em si, ficou evidente a importância de se fazer o refinamento de parâmetros (*hyperparameters tuning*). Uma escolha empírica e aleatória de parâmetros do classificador pode acarretar em uma perda significável de performance, como pode ser visto no K-NN ( $K$ s muito altos resultaram em acurácias baixas) e no LDA (*solver* Eigen teve uma taxa de acerto muito baixa, se comparado com os demais resultados). Estas conclusões destacadas são válidas para esta base de dados específica e não devem ser generalizadas para outras aplicações de classificação.

A avaliação final dos três melhores modelos de classificação provou que as configurações escolhidas generalizaram os classificadores, uma vez que todos os três seguiram obtendo resultados muito altos também no conjunto de testes, conjunto este totalmente desconhecido pelos modelos até então. Este comportamento deixa claro que não houve aleatoriedade e nem *overfitting* durante o refinamento dos parâmetros.

Apesar do presente estudo não compreender o desenvolvimento dos componentes mecânicos necessários para automatizar a batida do

martelo nas peças cerâmicas, os testes e experimentos aqui feitos demonstram a viabilidade técnica e computacional de se caracterizar telhas cerâmicas fazendo o uso de análise de emissão acústica.

Para trabalhos futuros pode-se considerar possíveis testes com outras técnicas de redução de dimensão da base de dados, como o uso de PCA (Principal Component Analysis) ou até mesmo outro método de seleção de características. Pode-se também avaliar o desempenho de outros algoritmos de classificação, como redes neurais artificiais, árvores de decisão entre outros. Para se aproximar mais do cenário real de implementação deste sistema, um trabalho futuro interessante seria a utilização de microfones direcionais mais apropriados para este tipo de captação, assim como o uso de uma placa de aquisição de sinais dedicada a este propósito. Por fim, visando a implementação do sistema no chão de fábrica, precisa-se fazer a criação de um dispositivo mecânico automatizado para realizar de forma autônoma a batida física nas telhas cerâmicas.

## REFERÊNCIAS

- ABC. *ABC - Associação Brasileira de Cerâmica*. jan 2013. <<http://www.abceram.gov.br>>.
- ABENDI. *ENSAIOS NÃO DESTRUTIVOS E INSPEÇÃO*. 2017. <<http://www.abendi.org.br/abendi/default.aspx?mn=709&c=17>>.
- AKINCI, T. C. The Defect Detection in Ceramic Materials Based on Time-Frequency Analysis by Using the Method of Impulse Noise. *Archives of Acoustics*, v. 36, n. 1, p. 77–85, 2011. ISSN 0137-5075.
- AL-ANZI, F. S.; ABUZEINA, D. Arabic Text Classification Using Linear Discriminant Analysis. In: *ICEMIS2017*. [S.l.: s.n.], 2017. ISBN 9781509067787.
- ALTAY, O. Prediction of the Autism Spectrum Disorder Diagnosis with Linear Discriminant Analysis Classifier and K-Nearest Neighbor in Children. p. 1–4, 2018.
- ANDRADE ENRICO ESPOSITO, N. P. G. M. R. R. M. D. *Nondestructive techniques for detection of delamination in ceramic tile: a laboratory comparison between IR thermal cameras and laser Doppler vibrometers*. 1999. 3585 - 3585 - 11 p.
- ANICER. *ANICER*. oct 2015. <<http://portal.anicer.com.br>>.
- BARTSCH, M.; WAKEFIELD, G. H. To catch a chorus: using chroma-based representations for audio thumbnailing. *Workshop on the Applications of Signal Processing to Audio and Acoustics*, n. October, p. 15–18, 2001.
- BARTSCH, M. A.; WAKEFIELD, G. H. Audio thumbnailing of popular music using chroma-based representations. *IEEE Transactions on Multimedia*, v. 7, n. 1, p. 96–104, Feb 2005. ISSN 1520-9210.
- BASTOS, F. A. *AVALIAÇÃO DO PROCESSO DE FABRICAÇÃO DE TELHAS E BLOCOS CERÂMICOS VISANDO A CERTIFICAÇÃO DO PRODUTO*. Dissertação (Mestrado) — UFSC - Universidade Federal de Santa Catarina, 2003.
- BAUER, L. A. F. *Materiais de Construção - Volume 1 (Em Portuguese do Brasil)*. [S.l.]: LTC Editora, 1994. ISBN 8521612494.

- BEATTIE, A. G. Acoustic Emission Non-Destructive Testing of Structures using Source Location Techniques. n. September, p. 128, 2013.
- CAI, J. et al. Feature selection in machine learning: A new perspective. *Neurocomputing*, Elsevier B.V., v. 0, p. 1–10, 2018. ISSN 18728286.
- CARDOSO, J. F. d. S. *Predição da qualidade na indústria de fundição injetada.PDF*. Tese (Doutorado) — Faculdade de Engenharia da Universidade do Porto, 2001.
- CHANDRASHEKAR, G.; SAHIN, F. A survey on feature selection methods. *Computers and Electrical Engineering*, Elsevier Ltd, v. 40, n. 1, p. 16–28, 2014. ISSN 00457906.
- Chih-Wei Hsu, Chih-Chung Chang; LIN, C.-J. A Practical Guide to Support Vector Classification. *BJU international*, v. 101, n. 1, p. 1396–400, 2008. ISSN 1464-410X.
- DEMIDOVA, L.; KLYUEVA, I. Svm classification: Optimization with the smote algorithm for the class imbalance problem. In: *2017 6th Mediterranean Conference on Embedded Computing (MECO)*. [S.l.: s.n.], 2017. p. 1–4.
- DEMIDOVA, L. et al. Intellectual approaches to improvement of the classification decisions quality on the base of the svm classifier. *Procedia Computer Science*, v. 103, p. 222 – 230, 2017. ISSN 1877-0509. XII International Symposium Intelligent Systems 2016, INTELS 2016, 5-7 October 2016, Moscow, Russia.
- EBERTZ, R. *AVALIAÇÃO DAS CONDIÇÕES COMPETITIVAS DA INDÚSTRIA CERÂMICA DE REVESTIMENTO DA REGIÃO SUL DE SANTA CATARINA*. Tese (Doutorado) — UNIVERSIDADE FEDERAL DE SANTA CATARINA, 2005.
- FALCÃO, M. Semantic Characterization of Objects. *Building*, 2002.
- FALCÃO, M.; VIEIRA, J.; FERREIRA, A. CLASSIFICAÇÃO AUTOMÁTICA DE TIJOLOS. 2003.
- FANG, W. et al. Parallel data mining on graphics processors. *Hong Kong University of Science and Technology, Tech. Rep. HKUST-CS08-07*, p. 1, 2008.
- FIESC. *Rotas Estratégicas Setoriais para a Indústria Catarinense 2022: Cerâmica*. [S.l.], 2014.

FIESC. *Rotas Estratégicas Setoriais 2022 – Cerâmica*. [S.l.], 2015.

FONTI, V.; BELITSER, E. Feature Selection using LASSO. 2017.

GIANNAKOPOULOS, A. P. T. Introduction to audio analysis: A matlab approach. In: \_\_\_\_\_. [S.l.]: Academic Press, 2014. v. 1, cap. Chapter 4 – Audio Features.

GIANNAKOPOULOS, T.; PETRIDIS, S. Unsupervised speaker clustering in a linear discriminant subspace. In: *2010 Ninth International Conference on Machine Learning and Applications*. [S.l.: s.n.], 2010. p. 1005–1009.

GODA, K. Defect Detection Using Impact Acoustic Method in Concrete Models. n. May, 2014.

GORDILLO, C. D. A. *Reconhecimento de voz contínua combinando os atributos MFCC e PNCC com métodos de Robustez SS, WD, MAP e FRN*. Tese (Doutorado) — Pontifícia Universidade Católica do Rio de Janeiro, 2013.

ISHIKAWA, K. *Controle De Qualidade Total - à Maneira Japonesa*. [S.l.]: Campus, 1993.

JIANG, Z. D.; LUK, B. L.; LIU, K. P. Bispectra-based impact acoustic non-destructive evaluation. *NDT and E International*, Elsevier, v. 42, n. 7, p. 652–657, 2009. ISSN 09638695.

JÚNIOR, L. N. Processamento de telhas cerâmicas por compactação de pós e queima em forno a rolo. p. 74, 2008.

KAMKAR, I. et al. Stable feature selection for clinical prediction: Exploiting ICD tree structure using Tree-Lasso. *Journal of Biomedical Informatics*, Elsevier Inc., v. 53, p. 277–290, 2015. ISSN 15320464.

KIM, H.-G.; MOREAU, N.; SIKORA, T. *MPEG-7 Audio and Beyond: Audio Content Indexing and Retrieval*. Wiley, 2005. ISBN 047009334X. <<https://www.amazon.com/MPEG-7-Audio-Beyond-Indexing-Retrieval/dp/047009334X?SubscriptionId=0JYN1NVW651KCA56C102tag=tech20linkCode=xm2camp=2025creative=165953creativeASIN=047009334X>>.

KIM, J.; KRUTCHKOFF, R. G.; TERRELL, G. R. Iterated grid search algorithm on unimodal criteria. *Virginia Polytechnic Institute and State University*, p. 1–116, 1997.

LANGLEY, P. *Elements of Machine Learning*. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1995. ISBN 1-55860-301-8.

LEE, C.; LANDGREBE, D. Feature extraction and classification algorithms for high dimensional data. *ECE Technical Reports*.

MEDEIROS, E. N. M. D. *SISTEMA DE GESTÃO DA QUALIDADE NA INDÚSTRIA CERÂMICA VERMELHA. ESTUDO DE CASO DE UMA INDÚSTRIA QUE ABASTECE O MERCADO DE BRASÍLIA*. Tese (Doutorado) — UNIVERSIDADE DE BRASÍLIA, 2006.

MISRA, H. et al. Spectral entropy based feature for robust asr. In: *2004 IEEE International Conference on Acoustics, Speech, and Signal Processing*. [S.l.: s.n.], 2004. v. 1, p. I-193-6 vol.1. ISSN 1520-6149.

MULLER, M.; KURTH, F.; CLAUSEN, M. Chroma-based statistical audio features for audio matching. *IEEE Workshop on Applications of Signal Processing to Audio and Acoustics*, p. 275-278, 2005.

MURAVIN, B. Acoustic emission science and technology. *Journal of Building and Infrastructure Engineering of The Israeli Association of Engineers and Architects*, n. Figure 1, p. 1-12, 2009.

MUTHUKRISHNAN, R.; ROHINI, R. Lasso: A feature selection technique in predictive modeling for machine learning. In: *2016 IEEE International Conference on Advances in Computer Applications (ICACA)*. [S.l.: s.n.], 2016. p. 18-20.

Nandhini Shenbagavalli, S. A.; SCHOLAR, P. Voiced/Unvoiced Detection using Short Term Processing. *International Journal of Computer Applications*, p. 975-8887, 2014.

NAZARCHUK, Z.; SKALSKYI, V.; SERHIYENKO, O. *Acoustic Emission: Methodology and Application (Foundations of Engineering Mechanics)*. [S.l.]: Springer, 2017.

OPPENHEIM, A. V.; SCHAFER, R. W.; BUCK, J. R. *Discrete-time Signal Processing (2Nd Ed.)*. Upper Saddle River, NJ, USA: Prentice-Hall, Inc., 1999. ISBN 0-13-754920-2.

OTHMAN, N. H. et al. Linear discriminant analysis for detection of salivary NS1 from SERS spectra. *IEEE Region 10 Annual International Conference, Proceedings/TENCON*, v. 2017-December, p. 2876-2879, 2017. ISSN 21593450.

PEDREGOSA, F. et al. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, v. 12, p. 2825–2830, 2011.

PEDREGOSA, F. et al. Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, v. 12, p. 2825–2830, 2012. ISSN 15324435.

PEETERS, G. A large set of audio features for sound description (similarity and classification) in the CUIDADO project. *CUIDADO IST Project Report*, v. 54, n. 0, p. 1–25, 2004. ISSN nul.

PEREIRA, M. A. Determinação de parâmetros da qualidade para a avaliação de recobrimentos superficiais de telhas cerâmicas. p. 122, 2006.

PROAKIS, J. G.; MANOLAKIS, D. K. *Digital Signal Processing (4th Edition)*. [S.l.]: Pearson, 2006. ISBN 0131873741.

RABINER, L. R.; SAMBUR, M. R. An algorithm for determining the endpoints of isolated utterances. *The Bell System Technical Journal*, v. 54, n. 2, p. 297–315, Feb 1975. ISSN 0005-8580.

RANACHOWSKI, P.; REJMUND, F. Mechanical-Acoustic Examination of Ceramic Material. 2008.

RAO, P. Audio Signal Processing. p. 169–189, 2008. ISSN 1860949X.

RAUT, S.; RALEGAONKAR, R.; MANDAVGANE, S. Development of sustainable construction material using industrial and agricultural solid waste: A review of waste-create bricks. *Construction and Building Materials*, v. 25, n. 10, p. 4037 – 4042, 2011. ISSN 0950-0618.

ROBERTS, S. Lecture 7 - The Discrete Fourier Transform. *Oxford Robots Lecture*, p. 82–96, 2003.

RODRIGUEZ, M. A.; VERGARA, L.; MORALES, J. REAL-TIME PROTOTYPY ' E FOR MICROCRACKS DETECTION ON CERAMIC MATERIALS. p. 2–5, 1996.

ROMAGNOLI, M. et al. A non-destructive method to assess delamination of ceramic tiles. *Journal of the European Ceramic Society*, v. 27, n. 2-3, p. 1631–1636, 2007. ISSN 09552219.

S., S. et al. Accelerating k-nn classification algorithm using graphics processing units. In: *2016 IEEE International Conference on Information and Automation for Sustainability (ICIAfS)*. [S.l.: s.n.], 2016. p. 1–6.

SAMBORSKI, S.; SADOWSKI, T. Experimental investigations and modelling of porous ceramics. In: \_\_\_\_\_. *IUTAM Symposium on Multiscale Modelling of Damage and Fracture Processes in Composite Materials: Proceedings of the IUTAM Symposium held in Kazimierz Dolny, Poland, 23–27 May 2005*. Dordrecht: Springer Netherlands, 2006. p. 263–270. ISBN 978-1-4020-4566-0.

SEBRAE. Cerâmica Vermelha. *Boletim De Inteligência*, p. 1–5, 2015. ISSN 2176-9427.

SHEN, Y. et al. Feasibility of Non-Destructive Internal Quality Analysis of Pears by Using Near-Infrared Diffuse Reflectance Spectroscopy. In: *The 9th International Conference on Modelling, Identification and Control (ICMIC 2017)*. [S.l.: s.n.], 2017.

SILVA, C.; M, M. P. Restrictive factors in implementation of clean technologies in red ceramic industries. v. 168, 2017.

SINDICER. *Sindicato da Indústria da Cerâmica Vermelha - SINDICER*. jan 2018. <<http://www.sindicermf.com.br/?link=sindicer>>.

SLANEY, M. Auditory toolbox: A Matlab Toolbox for Auditory Modeling Work. *Interval Research Corporation, Tech. Rep*, v. 10, p. 1998, 1998. <[http://www.tka4.org/materials/lib/Articles-Books/Speech Recognition/AuditoryToolboxTechReport.pdf](http://www.tka4.org/materials/lib/Articles-Books/Speech%20Recognition/AuditoryToolboxTechReport.pdf)>.

SOUZA, M. *Telhas Cerâmicas*. 2018. <<http://anicer.com.br/telhas-ceramicas/>>.

THEODORIDIS, S.; KOUTROUMBAS, K. *Pattern Recognition, Fourth Edition*. [S.l.]: Academic Press, 2008. ISBN 1597492728.

TONG, F.; TSO, S. K.; XU, X. M. Tile-wall bonding integrity inspection based on time-domain features of impact acoustics. *Sensors and Actuators, A: Physical*, v. 132, n. 2, p. 557–566, 2006. ISSN 09244247.

TZANETAKIS, G.; COOK, P. Musical genre classification of audio signals. *IEEE Transactions on Speech and Audio Processing*, v. 10, n. 5, p. 293–302, Jul 2002. ISSN 1063-6676.

WAKEFIELD, G. H. Mathematical representation of joint time-chroma distributions. *SPIE Conference on Advanced Signal Processing Algorithms, Architectures, and Implementations IX*, v. 3807, n. July, p. 637–645, 1999. ISSN 0277786X.

WONG, T. T.; YANG, N. Y. Dependency analysis of accuracy estimates in k-fold cross validation. *IEEE Transactions on Knowledge and Data Engineering*, v. 29, n. 11, p. 2417–2427, Nov 2017. ISSN 1041-4347.

XIN, Y. et al. Machine Learning and Deep Learning Methods for Cybersecurity. v. 3536, n. c, 2018.

ZHANG, Y.; GUO, W.; EDU, C. On the Consistency of Feature Selection With Lasso for Non-linear Targets. *Icml*, v. 48, 2016.

ZOLIN, I. *Ensaio Mecânicos e Análises de Falhas*. [S.l.], 2011.