Universidade do Estado do Rio de Janeiro

Centro de Tecnologia e Ciências

Faculdade de Engenharia

Amanda de Oliveira Sabino das Chagas

Detecção de Risco de Queda de Hospitalizados Através da Informação do Estado do Canal Sem-Fio

Rio de Janeiro

2021

Amanda de Oliveira Sabino das Chagas

Detecção de Risco de Queda de Hospitalizados Através da Informação do Estado do Canal Sem-Fio

Dissertação apresentada como requisito parcial para obtenção do título de Mestre em Engenharia Eletrônica, ao Programa de Pós-Graduação em Engenharia Eletrônica, da Universidade do Estado do Rio de Janeiro.
Área de Concentração: Redes de Telecomunicações.
Linha de Pesquisa: Sinais e Sistemas de Comunicações.

Orientador: Prof Dr. Lisandro Lovisolo

Orientador: Prof. Dr. Michel Pompeu Tcheou

Rio de Janeiro

2021

CATALOGAÇÃO NA FONTE
UERJ / REDE SIRIUS / BIBLIOTECA CTC/B

C433 Chagas, Amanda de Oliveira Sabino das.
Detecção de risco de queda de hospitalizados através da informação do estado do canal sem-fio / Amanda de Oliveira Sabino das Chagas. – 2021.
170 f.

Orientadores: Lisandro Lovisolo, Michel Pompeu Tcheou.
Dissertação(Mestrado) – Universidade do Estado do Rio de Janeiro, Faculdade de Engenharia.

1. Engenharia eletrônica - Teses. 2. Sistemas de comunicação sem fio - Teses. 3. Algorítmos - Teses. 4. Redes locais sem fio - Teses. 5. Detectores - Teses. 6. Aprendizado do computador - Teses. I. Lovisolo, Lisandro. II. Tcheou, Michel Pompeu. III. Universidade do Estado do Rio de Janeiro, Faculdade de Engenharia. IV. Título.

CDU 621:391.812

Bibliotecária: Júlia Vieira – CRB7/6022

Autorizo, apenas para fins acadêmicos e científicos, a reprodução total ou parcial desta dissertação, desde que citada a fonte.

Assinatura Data

Amanda de Oliveira Sabino das Chagas

Detecção de Risco de Queda de Hospitalizados Através da Informação do Estado do Canal Sem-Fio

Dissertação apresentada como requisito parcial para obtenção do título de Mestre em Engenharia Eletrônica, ao Programa de Pós-Graduação em Engenharia Eletrônica, da Universidade do Estado do Rio de Janeiro.
Área de Concentração: Redes de Telecomunicações.
Linha de Pesquisa: Sinais e Sistemas de Comunicações.

Aprovado em: 13 de outubro de 2021

Banca Examinadora:

Prof. D. Sc. Lisandro Lovisolo (Orientador)
Faculdade de Engenharia - UERJ

Prof. D. Sc. Michel Pompeu Tcheou (Orientador)
Faculdade de Engenharia - UERJ

Prof. D. Sc. Alexandre Sztajnberg
Instituto de Matemática e Estatística - UERJ

Prof. D. Sc. João Baptista de Oliveira e Souza Filho
COPPE - UFRJ

Rio de Janeiro

2021

AGRADECIMENTO

Agradeço a Deus pela vida, saúde e neste momento tão difícil da humanidade por permitir a conclusão deste trabalho.

Aos meus pais, Sandra e Felipe, as minhas avós Alice e Dedira (in memorian) por todo amor, carinho, compreensão e pelo incentivo em todos os momentos da minha vida para que eu pudesse chegar até aqui.

Ao meu marido, José Eduardo, pelo apoio, incentivo, por não deixar eu desistir, por acreditar que eu seria capaz e por ser sempre o meu melhor amigo.

A minha amiga Adriane Duarte, companheira da vida acadêmica, pela força, por estar disposta a me escutar por longas horas, pelo apoio em tantos momentos e espero levar nossa amizade para sempre.

Aos meus professores e orientadores, Lisandro Lovisolo e Michel Tcheou, pelo incentivo, pela confiança, pela disponibilidade de sempre ajudar e por acreditar que eu poderia desenvolver este trabalho. Agradeço desde a graduação até este momento, pela dedicação, generosidade em compartilhar seus conhecimentos e grande contribuição na minha vida acadêmica.

As amigas Gabrielle Silva, Adriene Duarte, Nathália Valadão e Simone Cordeiro pelo apoio.

A Faculdade de Engenharia Elétrica da Universidade do Rio de Janeiro e a todos os professores que contribuíram para minha vida acadêmica.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

RESUMO

CHAGAS, Amanda de Oliveira Sabino das. *Detecção de Risco de Queda de Hospitalizados Através da Informação do Estado do Canal Sem-Fio.* 170 f. Dissertação (Mestrado em Engenharia Eletrônica) - Faculdade de Engenharia, Universidade do Estado do Rio de Janeiro (UERJ), Rio de Janeiro, 2021.

A Informação do Estado do Canal (CSI - *Channel State Information*) está disponível em redes sem-fio do padrão IEEE 802.11. A CSI traz informação sobre o ambiente de propagação através da amplitude e fase das subportadoras OFDM. Neste estudo, emprega-se a CSI para a detecção de risco de queda de pacientes hospitalizados. Detecta-se a mudanças no ambiente de propagação do sinal sem fio e a partir deste princípio não-intrusivo são implementados detectores de risco de queda em ambiente hospitalar. Os detectores propostos detectam o risco como anomalias no ambiente a partir da identificação de alterações no ambiente de propagação. Propomos três detectores usando diferentes algoritmos de aprendizagem de máquina: kNN (k-*Nearest Neighbors*), PCA (*Principal Component Analysis*) e Autoencoder. Para cada um deles são escolhidos os pontos de corte a partir da técnica de testes e diagnósticos da Curva ROC, obtendo acurácias de até 87,33% para o kNN, 93,00% para o PCA e 90,92% para o Autoencoder. Para esse trabalho é desenvolvido um banco de dados de situações normais e de risco de queda. Além da análise global do detector de risco de queda por anomalias, avalia-se como diferentes tipos de queda comprometem o funcionamento dos detectores de anomalias, ao usá-los para classificar as situações como de risco ou sem risco de queda.

Palavras-chave: Detecção de queda. classificadores. detecção de anomalias. CSI.

ABSTRACT

CHAGAS, Amanda de Oliveira Sabino das. *Fall Risk Detection in Hospitalized Through Wireless Channel State Information.* 170 f. Dissertação (Mestrado em Engenharia Eletrônica) - Faculdade de Engenharia, Universidade do Estado do Rio de Janeiro (UERJ), Rio de Janeiro, 2021.

Channel Status Information (CSI) is available on IEEE 802.11 wireless networks. The CSI carries information regarding the propagation environment through the amplitude and phase of the OFDM subcarriers. In this study, CSI is used to detect the risk of falling in hospitalized patients. CSI is applied to detect changes in the wireless signal propagation environment and, regarding this non-intrusive principle, fall risk detectors are implemented in a hospital environment. The proposed detectors detect fall risk as anomalies in the environment from changes in the propagation environment. We propose three detectors using different machine learning algorithms: kNN(k-*Nearest Neighbors*), PCA (*Principal Component Analysis*) and Autoencoder. For each of them, the cutoff points are chosen based on the technique of tests and diagnostics of the ROC Curve, obtaining accuracies up to 87.33% for kNN, 93.00% for PCA and 90.92% for Autoencoder. For this work, a database of normal condition and fall risk is developed. In addition to the global analysis of the fall risk detector due to anomalies, we evaluated how different types of falls compromise the functioning of the anomaly detectors, using them to classify situations as risky or without risk of falling.

Keywords: Fall detection. classifiers. anomaly detection. CSI.

LISTA DE FIGURAS

Figura 1 - Infográfico do número de casos acumulados no Brasil 25
Figura 2 - Infográfico do número de mortes acumuladas no Brasil..... 25
Figura 3 - Fluxograma da Metodologia do Trabalho..... 26
Figura 4 - Modelos de Referência OSI e IEEE 802.11 32
Figura 5 - Canais de dados OFDM no padrão IEEE 802.11..... 36
Figura 6 - Categorias de preâmbulos 802.11n 37
Figura 7 - Estrutura do pacote 802.11a..... 38
Figura 8 - Estrutura do pacote preâmbulo de formato misto..... 39
Figura 9 - FDM e OFDM 40
Figura 10 - OFDM com subportadoras..... 41
Figura 11 - Diagrama de bloco de um sistema de comunicação digital multiportadora OFDM 41
Figura 12 - Representação do ambiente sem obstrução e com obstrução do sinal..... 45
Figura 13 - Esquema de monitoramento CSI 48
Figura 14 - Configurações do Ponto de Acesso Wireless no ambiente de teste 49
Figura 15 - Amplitude das Subportadoras OFDM (CSI) 51
Figura 16 - Local do monitoramento CSI 52
Figura 17 - Situação Sem risco de queda e Com risco de queda..... 53
Figura 18 - Representação das modalidades de aprendizado de máquina..... 54
Figura 19 - Representação de kNN com dois rótulos de classe e para diferentes valores de K 56
Figura 20 - Gráfico da Variação Explicada para cada componente principal CSI..... 60
Figura 21 - Representação Resumida do Autoencoder 62
Figura 22 - Representação do Autoencoder 63
Figura 23 - Representação das Funções ReLU e Sigmoide 64
Figura 24 - Desempenho do Classificador pela Curva ROC..... 68
Figura 25 - Desempenho do Classificador pela Curva ROC e AUC 69
Figura 26 - Ponto de Corte 1 70
Figura 27 - Classificação da amostra da CSI a partir do Ponto de Corte..... 71

Figura 28 - Desempenho do Classificador de acordo com Limiar 72
Figura 29 - Tipos de validação dos dados 74
Figura 30 - Representação do Classificador baseado em kNN 80
Figura 31 - Curva ROC do kNN para diferentes valores de k - validação *Hold-out* 82
Figura 32 - Localização dos pontos de corte para o classificador baseado em kNN para $k = 3$ - validação *Hold-out* 82
Figura 33 - Localização dos pontos de corte na Curva ROC para $k = 3$ - validação *Hold-out* 83
Figura 34 - Matriz de Confusão e Amostras TP e FP para os pontos de corte no classificador baseado em kNN para $k = 3$ - validação *Hold-out* 84
Figura 35 - Localização dos pontos de corte no classificador baseado em kNN para $k = 3$ - validação cruzada *k-Fold* - 2^a partição 86
Figura 36 - Localização dos pontos de corte na Curva ROC no classificador baseado em kNN para $k = 3$ - validação cruzada *k-Fold* - 2^a partição 86
Figura 37 - Matriz de Confusão e Amostras TP e FP para os pontos de corte no classificador baseado em kNN para $k = 3$ - validação cruzada *k-Fold* - 2^a partição 88
Figura 38 - Localização dos pontos de corte no classificador baseado em kNN para $k = 3$ - validação cruzada *k-Fold* - 3^a partição 89
Figura 39 - Localização dos pontos de corte na Curva ROC no classificador baseado em kNN para $k = 3$ - validação cruzada *k-Fold* - 3^a partição 89
Figura 40 - Matriz de Confusão e Amostras TP e FP para os pontos de corte no classificador baseado em kNN para $k = 3$ - validação cruzada *k-Fold* - 3^a partição 91
Figura 41 - Distribuição do conjunto de dados no classificador baseado em kNN para $k = 3$ para os diferentes métodos de validação 92
Figura 42 - Representação do Classificador baseado em PCA 94
Figura 43 - Gráfico para análise de componentes principais e autovalores no classificador baseado em PCA 96
Figura 44 - Localização dos pontos de corte no classificador baseado em PCA para 3 CPs - validação *Hold-out* 97

Figura 45 - Localização dos pontos de corte na Curva ROC no classificador baseado em PCA para 3 CPs - validação *Hold-out* 97
Figura 46 - Matriz de Confusão e Amostras TP e FP para os pontos de corte no classificador baseado em PCA para 3 CPs - validação *Hold-out* 98
Figura 47 - Localização dos pontos de corte no classificador baseado em PCA para 3 CPs - validação cruzada *k-Fold* - 2^a partição 100
Figura 48 - Localização dos pontos de corte na Curva ROC no classificador baseado em PCA para 3 CPs - validação cruzada *k-Fold* - 2^a partição 100
Figura 49 - Matriz de Confusão e Amostras TP e FP para os pontos de corte no classificador baseado em PCA para 3 CPs - validação cruzada *k-Fold* - 2^a partição 101
Figura 50 - Localização dos pontos de corte no classificador baseado em PCA para 3 CPs - validação cruzada *k-Fold* - 3^a partição 102
Figura 51 - Localização dos pontos de corte na Curva ROC no classificador baseado em PCA para 3 CPs - validação cruzada *k-Fold* - 3^apartição 102
Figura 52 - Matriz de Confusão e Amostras TP e FP para os pontos de corte no classificador baseado em PCA para 3 CPs - validação cruzada *k-Fold* - 3^a partição 103
Figura 53 - Distribuição do conjunto de dados no classificador baseado em PCA para 3 CPs para os diferentes métodos de validação 105
Figura 54 - Representação do Classificador baseado em Autoencoder 106
Figura 55 - Curva ROC do Autoencoder para 3 Modelos 108
Figura 56 - Localização dos pontos de corte no classificador baseado em Autoencoder - modelo 3 - validação *Hold-out* 108
Figura 57 - Localização dos pontos de corte na Curva ROC no classificador baseado em Autoencoder - modelo 3 - validação *Hold-out* 109
Figura 58 - Matriz de Confusão e Amostras TP e FP para os pontos de corte no classificador baseado em Autoencoder - modelo 3 - validação *Hold-out* 110
Figura 59 - Localização dos pontos de corte para o classificador baseado em Autoencoder - modelo 3 - validação *k-Fold* - 2^a partição 112
Figura 60 - Localização dos pontos de corte na Curva ROC para classificador baseado em Autoencoder - modelo 3 - validação cruzada *k-Fold* - 2^a partição .. 112

Figura 61 - Matriz de Confusão e Amostras TP e FP para os pontos de corte no classificador baseado em Autoencoder - modelo 3 - validação cruzada *k-Fold* - 2^a partição 113
Figura 62 - Localização dos pontos de corte para o classificador baseado em Autoencoder - modelo 3 - validação *k-Fold* - 5^a partição 114
Figura 63 - Localização dos pontos de corte na Curva ROC para classificador baseado em Autoencoder - modelo 3 - validação cruzada *k-Fold* - 5^a partição .. 114
Figura 64 - Matriz de Confusão e Amostras TP e FP para os pontos de corte no classificador baseado em Autoencoder - modelo 3 - validação cruzada *k-Fold* - 5^a partição 115
Figura 65 - Distribuição do conjunto de dados no classificador baseado em Autoencoder no modelo 3 para os diferentes métodos de validação..... 117
Figura 66 - Curva ROC dos modelos escolhidos para treinamento dos classificadores . 118
Figura 67 - Pulso com mínima largura de banda que satisfaz o primeiro critério de Nyquist e o seu espectro 134
Figura 68 - Prefixo Cíclico 134
Figura 69 - ESP32 135
Figura 70 - Informações CSI de diferentes campos de treinamento 136
Figura 71 - Curva ROC para o classificador baseado em kNN separado por grupos para diferentes valores de k - validação *Hold-out* 137
Figura 72 - Localização dos pontos de corte do classificador baseado em kNN para $k = 3$ - Grupo 1 - validação *Hold-out*..... 138
Figura 73 - Localização dos pontos de corte na Curva ROC do classificador baseado em kNN para $k = 3$ - Grupo 1 - validação *Hold-out*..... 138
Figura 74 - Matriz de Confusão e amostras TP e FP dos pontos de corte no classificador baseado em kNN para $k = 3$ - Grupo 1 - validação *Hold-out*..... 139
Figura 75 - Localização dos pontos de corte do classificador baseado em kNN para $k = 3$ - Grupo 2 - validação *Hold-out*..... 140
Figura 76 - Localização dos pontos de corte na Curva ROC do classificador baseado em kNN para $k = 3$ - Grupo 2 - validação *Hold-out*..... 140
Figura 77 - Matriz de Confusão e amostras TP e FP dos pontos de corte no classificador baseado em kNN para $k = 3$ - Grupo 2 - validação *Hold-out*..... 141

Figura 78 - Localização dos pontos de corte do classificador baseado em kNN para $k = 3$ - Grupo 3 - validação *Hold-out* 142
Figura 79 - Localização dos pontos de corte na Curva ROC do classificador baseado em kNN para $k = 3$ - Grupo 3 - validação *Hold-out* 142
Figura 80 - Matriz de Confusão e amostras TP e FP dos pontos de corte no classificador baseado em kNN para $k = 3$ - Grupo 3 - validação *Hold-out* 143
Figura 81 - Localização dos pontos de corte do classificador baseado em kNN para $k = 3$ - Grupo 4 - validação *Hold-out* 144
Figura 82 - Localização dos pontos de corte na Curva ROC do classificador baseado em kNN para $k = 3$ - Grupo 4 - validação *Hold-out* 144
Figura 83 - Matriz de Confusão e amostras TP e FP dos pontos de corte no classificador baseado em kNN para $k = 3$ - Grupo 4 - validação *Hold-out* 145
Figura 84 - Distribuição do conjunto de dados para o classificador baseado em kNN para $k = 3$ - validação *Hold-out* 147
Figura 85 - Curva ROC do classificador baseado em PCA com 3 CPs por Grupos - validação *Hold-out* 148
Figura 86 - Localização dos pontos de corte do classificador baseado em PCA com 3 CPs - Grupo 1 - validação *Hold-out* 149
Figura 87 - Localização dos pontos de corte na Curva ROC do classificador baseado em PCA com 3 CPs - Grupo 1 - validação *Hold-out* 149
Figura 88 - Matriz de Confusão e amostras TP e FP dos pontos de corte no classificador baseado em PCA com 3 CPs - Grupo 1 - validação *Hold-out* 150
Figura 89 - Localização dos pontos de corte do classificador baseado em PCA com 3 CPs - Grupo 2 - validação *Hold-out* 151
Figura 90 - Localização dos pontos de corte na Curva ROC do classificador baseado em PCA com 3 CPs - Grupo 2 - validação *Hold-out* 151
Figura 91 - Matriz de Confusão e amostras TP e FP dos pontos de corte no classificador baseado em PCA com 3 CPs - Grupo 2 - validação *Hold-out* 152
Figura 92 - Localização dos pontos de corte do classificador baseado em PCA com 3 CPs - Grupo 3 - validação *Hold-out* 153
Figura 93 - Localização dos pontos de corte na Curva ROC do classificador baseado em PCA com 3 CPs - Grupo 3 - validação *Hold-out* 153

Figura 94 - Matriz de Confusão e amostras TP e FP dos pontos de corte no classificador baseado em PCA com 3 CPs - Grupo 3 - validação *Hold-out* 154
Figura 95 - Localização dos pontos de corte do classificador baseado em PCA com 3 CPs - Grupo 4 - validação *Hold-out* 155
Figura 96 - Localização dos pontos de corte na Curva ROC do classificador baseado em PCA com 3 CPs - Grupo 4 - validação *Hold-out* 155
Figura 97 - Matriz de Confusão e amostras TP e FP dos pontos de corte no classificador baseado em PCA com 3 CPs - Grupo 4 - validação *Hold-out* 156
Figura 98 - Distribuição do conjunto de dados para o classificador baseado em PCA com 3 CPs - validação *Hold-out* 158
Figura 99 - Curva ROC do classificador baseado em Autoencoder para diferentes modelos de Autoencoder - validação *Hold-out* 159
Figura 100 Localização dos pontos de corte do classificador baseado em Autoencoder - modelo 3 - Grupo 1 - validação *Hold-out* 160
Figura 101 Localização dos pontos de corte na Curva ROC do classificador baseado em Autoencoder - modelo 3 - Grupo 1 - validação *Hold-out* 160
Figura 102 Matriz de Confusão e amostras TP e FP dos pontos de corte no classificador baseado em Autoencoder - modelo 3 - Grupo 1 - validação *Hold-out* 161
Figura 103 Localização dos pontos de corte do classificador baseado em Autoencoder - modelo 3 - Grupo 2 - validação *Hold-out* 162
Figura 104 Localização dos pontos de corte na Curva ROC do classificador baseado em Autoencoder - modelo 3 - Grupo 2 - validação *Hold-out* 162
Figura 105 Matriz de Confusão e amostras TP e FP dos pontos de corte no classificador baseado em Autoencoder - modelo 3 - Grupo 2 - validação *Hold-out* 163
Figura 106 Localização dos pontos de corte do classificador baseado em Autoencoder - modelo 3 - Grupo 3 - validação *Hold-out* 164
Figura 107 Localização dos pontos de corte na Curva ROC do classificador baseado em Autoencoder - modelo 3 - Grupo 3 - validação *Hold-out* 164
Figura 108 Matriz de Confusão e amostras TP e FP dos pontos de corte no classificador baseado em Autoencoder - modelo 3 - Grupo 3 - validação *Hold-out* 165
Figura 109 Localização dos pontos de corte do classificador baseado em Autoencoder - modelo 3 - Grupo 4 - validação *Hold-out* 166

Figura 110 – Localização dos pontos de corte na Curva ROC do classificador baseado em Autoencoder - modelo 3 - Grupo 4 - validação *Hold-out* 166
Figura 111 – Matriz de Confusão e amostras TP e FP dos pontos de corte no classificador baseado em Autoencoder - modelo 3 - Grupo 4 - validação *Hold-out* 167
Figura 112 – Distribuição do conjunto de dados para o classificador baseado em Autoencoder - modelo 3 - validação *Hold-out* 169

LISTA DE TABELAS

Tabela 1 - Padrões IEEE 802.11 31
Tabela 2 - Padrões da camada PHY do IEEE 802.11 33
Tabela 3 - Dados das amostras da CSI coletados 50
Tabela 4 - Matriz de Confusão 66
Tabela 5 - Matriz de Confusão das amostras CSI 71
Tabela 6 - Resultados dos testes na validação cruzada *k-Fold* para Classificador baseado em kNN para $k = 3$ no ponto de corte 1 85
Tabela 7 - Resultados dos testes na validação cruzada *k-Fold* para Classificador baseado em kNN para $k = 3$ no ponto de corte 2 85
Tabela 8 - Acurácia nos dois pontos de corte das amostras de risco no Classificador baseado em kNN para $k = 3$ 92
Tabela 9 - Resultados dos testes na validação cruzada *k-Fold* para Classificador baseado em PCA para 3 CPs no ponto de corte 1 99
Tabela 10- Resultados dos testes na validação cruzada *k-Fold* para Classificador baseado em PCA para 3 CPs no ponto de corte 2 99
Tabela 11- Acurácia nos dois pontos de corte das amostras de risco no Classificador baseado em PCA para 3 CPs 104
Tabela 12- Resultados da validação cruzada *k-Fold* para Classificador baseado em Autoencoder modelo 3 no ponto de corte 1 111
Tabela 13- Resultados da validação cruzada *k-Fold* para Classificador baseado em Autoencoder modelo 3 no ponto de corte 2 111
Tabela 14- Acurácia nos dois pontos de corte das amostras de risco no Classificador baseado em Autoencoder - modelo 3 116
Tabela 15- Acurácia (%) nos pontos de corte - Validação *Hold-out* 118
Tabela 16- Acurácia média (%) nos pontos de corte - Validação cruzada *k-Fold* 119
Tabela 17- Acurácia para os diferentes grupos no Classificador baseado em kNN para $k = 3$ - validação *Hold-out* 146
Tabela 18- Acurácia para os diferentes grupos no Classificador baseado em PCA com 3 CPs - validação *Hold-out* 157

Tabela 19- Acurácia para os diferentes grupos no Classificador baseado em Auto-encoder - modelo 3 - validação *Hold-out* 168
Tabela 20- Acurácia (%) dos classificadores no ponto de corte 1 170
Tabela 21- Acurácia (%) dos classificadores no ponto de corte 2 170

LISTA DE SIGLAS

ADSL	*Assymetrical Digital Subscriber Line*
ANATEL	Agência Nacional de Telecomunicações
AP	*Access Point*
AUC	*Area Under the ROC Curve*
AWGN	*Additive white Gaussian noise*
BPSK	*Binary Phase Shift Keying*
CCK	*Complementary Code Keying*
CFO	*Carrier Frequency Offset*
CP	Componentes Principais
CSI	*Channel State Information*
DFT	*Discrete Fourier Transform*
DNN	*Deep Neural Networks*
DSSS	*Direct Sequence Spread Spectrum*
DT	*Decision Tree*
FDM	*Frequency Division Multiplexing*
FFT	*Fast Fourier Transform*
FHSS	*Frequency Hopping Spread Spectrum*
FNR	*False Negative Rate*
FPR	*False Positive Rate*
GMM	*Gaussian Mixture Models*
GPL	*General Public License*
HDTV	*High Definition Television*
HT-LTF	*High Throughput Long Training*
HT-SIG	*High Throughput Signal*
HT-STF	*High Throughput Short Training*
HUPE	Hospital Universitário Pedro Ernesto
IDFT	*Inverse Discrete Fourier Transform*
IEEE	*Institute of Electrical and Electronics Engineers*
IFFT	*Inverse Fast Fourier Transform*

IoT	*Internet of Things*
ISI	*Intersymbol Interference*
ISM	*Instrumentation, Scientific and Measurement*
ISO	*International Organization for Standardization*
kNN	*k-Nearest Neighbors Algorithm*
LLC	*Logical Link Control*
MAC	*Medium Access Control*
MF	*Mixed Format*
MIMO	*Multiple-Input and Multiple-Output*
MLP	*Multi Layer Perceptrons*
MU-MIMO	*Multi-User Multiple-Input Multiple-Output*
NIC	*Network Interface Card*
OFDM	*Orthogonal Frequency Division Multiplexing*
OSI	*Open Systems Interconnection*
PCA	*Principal Component Analysis*
PHY	*Physical Layer*
PLCP	*Physical Layer Convergence Procedure*
PMD	*Physical Medium Dependent*
QAM	*Quadrature Amplitude Modulation*
QPSK	*Quadrature Phase Shift Keying*
ReLU	*Rectified Linear Unit*
RF	*Radiofrequency*
ROC	*Receiver Operating Characteristic Curve*
RSSI	*Received Signal Strength Indication*
STFT	*Short-Time Fourier Transform*
SDM	*Spatial Division Multiplexing*
SVD	*Singular Value Decomposition*
SVM	*Support Vector Machine*
TG-ROC	*Two-Graph Receiver Operating Characteristic*
TNR	*True Negative Rate*
TPR	*True Positive Rate*
UDP	*User Datagram Protocol*

VHTT	*Very High Throughput*
VoD	*Video on Demand*
WLAN	*Wireless Local Area Network*
WSD	*White Space Devices*

SUMÁRIO

	INTRODUÇÃO	21
	Objetivo	22
	Metodologia	25
	Produção relacionada a este trabalho	27
	Estrutura da Dissertação	27
1	**FUNDAMENTAÇÃO**	29
1.1	**Trabalhos Relacionados**	29
1.2	**IEEE 802.11**	31
1.2.1	IEEE 802.11*a*	33
1.2.2	IEEE 802.11*g*	34
1.2.3	IEEE 802.11*n*	34
1.2.4	IEEE 802.11*ac*	35
1.2.5	Cabeçalho e Preâmbulo	36
1.3	**OFDM - *Orthogonal Frequency Division Multiplexing***	40
1.4	**CSI - *Channel State Information***	44
1.4.1	Formato da CSI	44
2	**METODOLOGIA DO PROJETO**	47
2.1	**Configuração do Microcontrolador**	47
2.2	**Captura da CSI**	50
2.2.1	Tratamento dos dados CSI	50
2.2.2	Área monitorada	51
2.2.3	Descrição do experimento	52
2.3	**Aprendizado de máquina para avaliar o sistema desenvolvido**	53
2.3.1	Aprendizado Supervisionado e Aprendizado não Supervisionado	54
2.3.2	kNN - *k-Nearest Neighbors Algorithm*	55
2.3.3	PCA - *Principal Component Analysis*	57
2.3.4	Autoencoder	61
2.4	**Curva ROC e métricas de avaliação**	65

2.5 **Normalização dos dados** ... 72
2.6 **Validação dos dados** ... 73
2.7 **Detecção de Risco de Queda** ... 73
2.8 **Implementação dos Classificadores para a Detecção de Risco de Queda** ... 76

3 **RESULTADOS: DESEMPENHOS DOS CLASSIFICADORES** ... 78
3.1 **Classificador Baseado em kNN** ... 79
3.1.1 Diagrama de Blocos do kNN ... 79
3.1.2 Pseudocódigo do Classificador kNN ... 80
3.1.3 Descrição dos Testes do Classificador kNN ... 81
3.1.4 Resultados ... 81
3.1.4.1 Validação *Hold-out* ... 82
3.1.4.2 Validação cruzada *k-Fold* ... 85
3.1.5 Análise dos Resultados do Classificador kNN ... 91
3.2 **Classificador Baseado em PCA** ... 93
3.2.1 Diagrama de Blocos da PCA ... 93
3.2.2 Pseudocódigo do Classificador PCA ... 94
3.2.3 Descrição dos Testes do Classificador PCA ... 95
3.2.4 Resultados ... 96
3.2.4.1 Validação *Hold-out* ... 96
3.2.4.2 Validação cruzada *k-Fold* ... 99
3.2.5 Análises dos Resultados do Classificador PCA ... 103
3.3 **Classificador Baseado em Autoencoder** ... 105
3.3.1 Diagrama de Blocos do Autoencoder ... 105
3.3.2 Pseudocódigo do Classificador Autoencoder ... 106
3.3.3 Descrição dos Testes do Classificador Autoencoder ... 107
3.3.4 Resultados ... 107
3.3.4.1 Validação *Hold-out* ... 108
3.3.4.2 Validação cruzada *k-Fold* ... 110
3.3.5 Análises dos Resultados do Classificador Autoencoder ... 116
3.4 Sumário Comparativo entre os Classificadores ... 118

CONCLUSÃO ... 120

REFERÊNCIAS 123

A **ASPECTOS DE IMPLEMENTAÇÃO** 130
A.1 IEEE 802.11 130
A.2 Sobre Sistemas OFDM 133
A.3 Alguns Aspectos do ESP32 135

B **AVALIAÇÃO DOS CLASSIFICADORES POR GRUPOS DE REGISTROS COM RISCO DE QUEDA** 137
B.1 Classificador Baseado em kNN 137
B.1.1 Análise dos Resultados do Classificador kNN 146
B.2 Classificador Baseado em PCA 148
B.2.1 Análise dos Resultados do Classificador PCA 157
B.3 Classificador Baseado em Autoencoder 159
B.3.1 Análise dos Resultados do Classificador Autoencoder 168
B.4 Sumário Comparativo entre os Classificadores para as Diferentes Situações de Risco de Queda 170

INTRODUÇÃO

Com a crescente demanda por aplicativos de segurança e saúde eletrônicas, a detecção humana prescindindo de dispositivos similares a peças de roupa, relógios, pulseiras ou configuração de câmeras [1] e sem o uso de dispositivos específicos, atrai cada vez mais interesse. A grande disponibilidade de redes locais sem fio, que alcançam praticamente todos os ambientes, permite empregá-las para adquirir informações de ambientes internos como a sua ocupação. A Informação do Estado do Canal (CSI — *Channel State Information*) e o Indicador da Intensidade do Sinal Recebido (RSSI — *Received Signal Strength Indication*) são medidas das redes sem fio que permitem essa detecção.

O RSSI caracteriza a atenuação de sinais de rádio durante sua propagação [2], estando disponível em diversas tecnologias. A CSI está disponível em protocolos de redes locais sem fio WLAN (*Wireless Local Area Network*) que utilizam a Multiplexação por Divisão de Frequências Ortogonais (OFDM — *Orthogonal Frequency Division Multiplex*), na qual a transmissão de dados é realizada dividindo-se a banda em subportadoras ortogonais [3]. As subportadoras de sistemas OFDM carregam dados em diferentes frequências, transmitidos simultaneamente, com isso pode-se estimar o estado do canal (a resposta) em cada subportadora. O conjunto dos valores com as respostas do canal nas diferentes subportadoras formam a chamada CSI [4].

O uso do OFDM em comunicações sem fio confere resistência a condições adversas do canal, como a propagação multipercurso. O OFDM é um esquema de modulação especialmente adequado para transmissão de alta taxa de dados em ambientes dispersivos com múltiplos retardos [5]. A presença de objetos reflexivos e dispersores no canal cria um ambiente em constante mudança que dissipa a energia do sinal em amplitude, fase e tempo. Esses efeitos resultam em várias versões do sinal transmitido atingindo a antena receptora, deslocadas umas das outras no tempo e em orientação espacial. A fase e as amplitudes aleatórias dos diferentes componentes dos múltiplos caminhos causam flutuações na intensidade do sinal, induzindo assim o desvanecimento em pequena escala, a distorção do sinal ou ambos [6].

A propagação de multipercurso frequentemente prolonga o tempo necessário para que uma parcela do sinal alcance o receptor produzindo a interferência inter-simbólica

(ISI - *Intersymbol Interference*). A ISI é um dos principais obstáculos à transmissão de dados em alta velocidade em canais sem fio [6]: múltiplas cópias do mesmo sinal alcançando o receptor com diferentes atrasos temporais. Assim, cada pulso produz diferentes versões com atrasos distintos, o que afeta um ou mais símbolos subsequentes afetando a recepção [7], isto é, réplicas atrasadas de símbolos anteriores interferem na detecção do símbolo atual [8].

A CSI é uma informação disponível na camada PHY (*physical*/física) refinada e descreve a amplitude e fase de cada subportadora no domínio da frequência [9, 10]. Ela representa a resposta do canal de um enlace (*link*) de radiofrequência, detalhando as condições de propagação, em cada subportadora entre o transmissor e receptor. No ambiente de propagação alguns efeitos podem afetar o sinal durante sua transmissão como espalhamento, desvanecimento e decaimento, e desse modo influenciar as subportadoras e resultando em variações na CSI.

Quando confrontadas as técnicas CSI e RSSI, observamos que o RSSI fornece apenas um valor para o enlace e a CSI, por sua vez, fornece várias medidas correspondentes às diferentes subportadoras, obtidas simultaneamente.

Como a CSI permite supervisionar mudanças no canal, essa técnica tem sido empregada para aplicações que requerem detecção de movimentos [2, 9, 11] ou autenticação de usuários de redes [12].

Objetivo

O objetivo deste trabalho é implementar um detector de risco de queda em ambiente hospitalar. Para tal fim, usa-se a CSI para obter informações do ambiente interno e detectar anormalidades.

O emprego da CSI de redes Wi-Fi para o monitoramento de risco se baseia na análise e detecção de mudanças do ambiente de propagação quando há movimentação no ambiente. Essa técnica é objeto de estudo para prover localização em ambiente internos, detectar movimentos e rastrear objetos. A assunção central é que uma mudança no ambiente (como, por exemplo, pacientes que levantam ou a ocorrência de uma queda) gera uma mudança no ambiente de RF (Radiofrequência) e consequentemente mudanças na CSI. Este trabalho visa implementar um detector de risco de quedas não-intrusivo em ambiente hospitalar a partir da CSI em dispositivos de comunicações via Wi-Fi/IEEE 802.11. Para identificar tais mudanças, coleta-se a CSI e alimenta-se um sistema especia-

lista para determinar se houve variações no ambiente ou não, isto é, realiza-se a detecção de movimentos.

O detector de movimento a partir da CSI permite o monitoramento com o uso de apenas alguns dispositivos Wi-Fi, sem utilizar câmeras de filmagem. De acordo com alguns pareceres emitidos por Conselhos de Medicina, câmeras de filmagem não são permitidas em salas de atendimento por questões de privacidade do paciente e do sigilo profissional [13–15]. Vejamos alguns trechos de pareceres emitidos por conselhos de medicina com orientações sobre instalação de tais dispositivos em ambiente hospitalar.

Ao solicitar informações sobre a instalação de câmeras em unidades hospitalares, [13] diz que no Brasil não existe resolução específica regulamentando o uso de câmeras de vigilância e que segundo a Constituição Federal, Artigo 5.º Inciso X, bem como no Código Civil, em seus artigos 11, 17 e 20, o parecer diz:

> "Concluindo, a utilização de câmaras de segurança no estacionamento médico, bem como no mezanino do plantão médico é legal, se a intenção for dar maior segurança, porém tais imagens não devem ser utilizadas para constranger o médico. A utilização de câmaras de segurança dentro do consultório médico, por ser uma área privativa, é ilegal e antiética, pois não preserva a intimidade do paciente nem o sigilo profissional. (OLIVEIRA, 2012)"

Em [14], arguiu-se sobre a instalação de câmeras no ambiente hospitalar com intuito educativo e melhoria assistencial pela análise de imagens. De acordo com [14], não há resolução específica do Conselho Federal de Medicina sobre a instalação de câmeras em ambiente e cita o Artigo 5.º, X da Constituição Brasileira sobre intimidade, a vida privada, a honra e as imagem das pessoas e conclui:

> "Diante do exposto, entendo que deve ser vedada a instalação de câmeras filmadoras nas salas de atendimento a pacientes nos serviços de emergência, pela impossibilidade de obter-se a autorização livre e consciente de todos os envolvidos — paciente ou representante legal, médicos e demais profissionais de saúde. (SOUZA, 2016)"

Complementarmente, [15] avalia a legalidade de instalação de câmeras de vigilância nas enfermarias, para permitir que a equipe de enfermagem possa acompanhar os pacientes

por monitoramento devido a dificuldades de visualizar o ambiente onde está instalada a enfermaria. O parecer [15] conclui:

> "Diante do exposto, entendo que deve ser vedada a instalação de câmeras de vigilância para o monitoramento contínuo de pacientes em leitos de enfermaria, pela impossibilidade de se obter a autorização livre e consciente de todos os envolvidos — paciente ou representante legal, médicos e demais membros da equipe de assistência à saúde. Os cuidados de segurança e de prevenção de eventos adversos devem ser adotados por protocolos ou métodos que não comprometam a intimidade de paciente e profissionais, como adequações arquitetônicas que possibilitem a visualização direta do paciente e o atendimento imediato do mesmo em caso de intercorrência; e adequado número de profissionais encarregados de monitorar os pacientes nas enfermarias. (STAUB, 2019)"

Como atualmente a rede sem fio (Wi-Fi) está disponível em praticamente todos os locais, a CSI é uma forma eficiente de realizar a detecção de movimentos em enfermarias e sinalizar possíveis situações de risco de queda.

A pretensão deste trabalho é testar o detector de risco de queda na enfermaria/ambulatório do *Hospital Universitário Pedro Ernesto - HUPE*. Em função da pandemia de Covid-19 [16] e do grande número de casos em todo país como se pode observar nas Figura 1 e Figura 2 disponíveis nos relatórios do Observatório Fluminense (COVID19RJ) [16] não é possível realizar atividades no ambiente hospitalar. Assim, foi necessário adaptar o trabalho para que se pudesse avaliar mudanças em cenários similares.

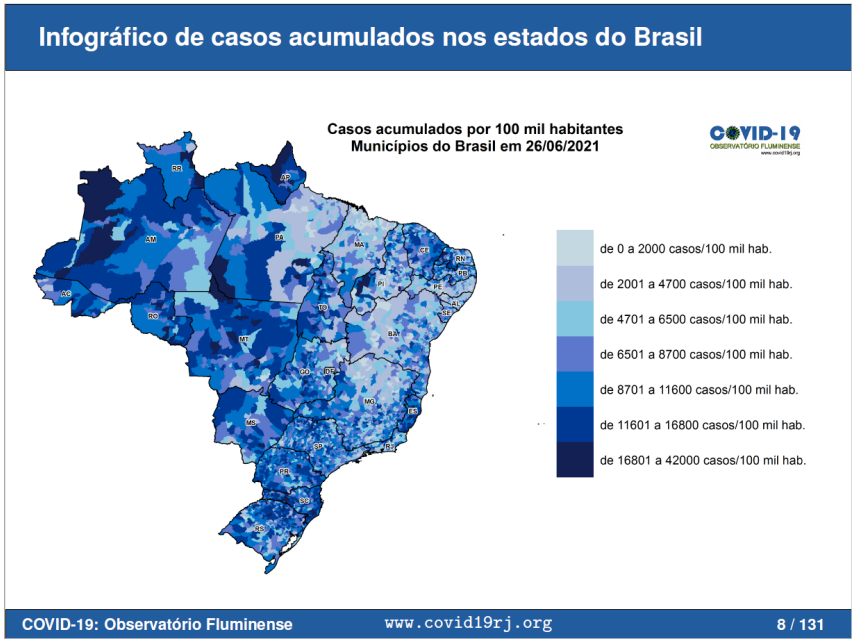

Figura 1: Infográfico do número de casos acumulados no Brasil [16].

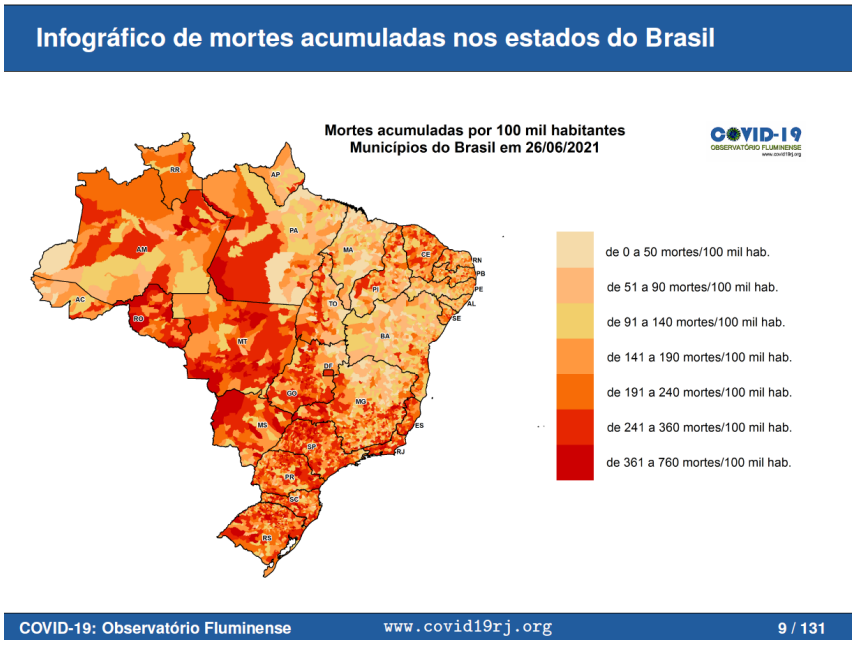

Figura 2: Infográfico do número de mortes acumuladas no Brasil [16].

Metodologia

Este trabalho visa desenvolver técnicas para a detecção de anomalias ou quedas no ambiente interno hospitalar, através do processamento da CSI obtido por intermédio de rede sem fio. A metodologia deste trabalho segue o diagrama de blocos apresentado na Figura 3.

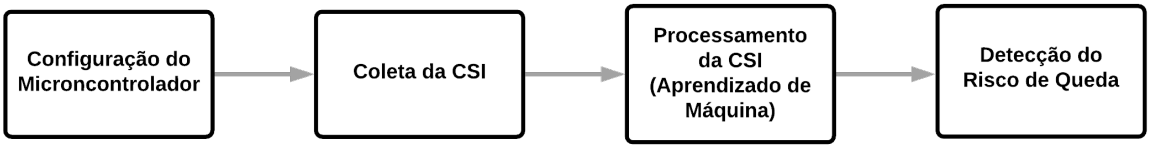

Figura 3: Fluxograma da Metodologia do Trabalho.

A CSI é adquirida através de um microcontrolador de baixo custo que possui diversos recursos, dentre os quais, a coleta de dados da rede sem fio e a obtenção da informação do estado do canal. O processamento da CSI é efetuado por algoritmos de aprendizado de máquina (*Machine Learning*) para identificar mudanças no estado do canal sem fio e determinar em qual momento ocorreram anomalias no ambiente. Na última fase, realiza-se a detecção do risco de queda no ambiente.

A CSI é composta por valores de amplitude e fase das subportadoras e flutua mesmo em ambientes estáticos. Assim, são utilizados algoritmos capazes de determinar padrões para o ambiente com situações conhecidas, e também quando ocorre alguma alteração.

Este trabalho desenvolve um detector de risco de queda em ambiente hospitalar, para que em situações nas quais há baixa disponibilidade de funcionários no hospital, como, por exemplo, a noite, o sistema indique se algum paciente levantou para que os responsáveis pela enfermaria possam atender pessoalmente e tomar as ações necessárias.

Os algoritmos empregados no detector de risco de queda aprendem o que representa a CSI de um ambiente desprovido de riscos de queda. São aplicados algoritmos de aprendizado de máquina já treinados com um modelo que reconhece se a CSI representa a classe/situação sem risco somente.

No caso de um paciente se levantar, esperam-se alterações na CSI. Tais alterações produzem alterações nas saídas dos modelos usados para sinalizar o risco de queda, isto é, o risco de queda é detectado como uma anomalia do estado sem risco de queda.

Essa abordagem é analisada usando as técnicas de aprendizado de máquina kNN (*k-Nearest Neighbors algorithm*), PCA (*Principal Component Analysis*) e Autoencoder. A escolha por esses algoritmos têm motivações distintas. O kNN é uma técnica simples, mas com capacidade de identificar variações e detectar diferenças entre os padrões originais de uso amplo e extenso. O PCA permite representar comprimidamente os dados de entrada (redução de dimensionalidade) usando uma metodologia linear e podemos assim comparar

os padrões num espaço de menor dimensão. Já o Autoencoder é capaz de aprender a representação compacta a partir dos dados originais de forma não linear.

Como a coleta da CSI não pode ser realizada em ambiente hospitalar devido à pandemia de COVID-19, como relatado na seção anterior, e com a finalidade de simular uma enfermaria fora do hospital, foi necessário representar um ambiente de testes e com auxílio de um voluntário onde foram simuladas algumas situações.

No ambiente de testes, são coletadas amostras da CSI em duas classes. O primeiro cenário é da classe "Sem risco de queda", em que o voluntário permanece deitado em uma cama enquanto as amostras da CSI são coletas. No segundo cenário, coletam-se novas amostras da CSI com o voluntário levantando da cama, simulando queda ou andando pelo ambiente que provavelmente vão gerar mudanças na CSI. Essas situações pertencem à classe "Com risco de queda".

As amostras CSI da classe "Com risco de queda" são reunidas em grupos e foram obtidas em períodos nos quais o voluntário, movimentou pelo ambiente de testes. As diferenças entre os desempenhos dos detectores de anomalias (treinados para reconhecer as amostras da classe "Sem risco de queda") para os diferentes grupos de risco de queda são avaliadas separadamente de forma a identificar e analisar possíveis diferenças de comportamento/desempenho entre eles.

Produção relacionada a este trabalho

Este trabalho resultou em um artigo aceito para publicação no XV Congresso Brasileiro de Inteligência Computacional - CBIC 21. CHAGAS, Amanda de O. Sabino das; LOVISOLO, Lisandro; TCHEOU, Michel P. Detecçao de Risco de Queda no Ambiente Hospitalar a partir da Informaçao do Estado do Canal Sem-Fio.

Estrutura da Dissertação

A estrutura da dissertação está estabelecida em uma Introdução com informações iniciais sobre o estudo, a motivação, o objetivo e a metodologia empregada para o desenvolvimento do detector de risco de quedas no ambiente hospitalar e mais três capítulos.

O Capítulo 1 apresenta os Fundamentos Teóricos para o desenvolvimento desta dissertação, com trabalhos relacionados a Informação do Estado do Canal (CSI) para a detecção de movimentos no ambiente interno, o padrão IEEE 802.11 que descreve os protocolos das redes Wi-Fi, o OFDM que é a técnica de transmissão de dados aplicada nas redes sem fio e a CSI que corresponde à estimação do canal sem fio.

No Capítulo 2, é esclarecida a metodologia do projeto, e são apresentados os dispositivos empregados e a forma de implantá-los para a coleta e tratamento dos dados de CSI. Além disso, são descritas as técnicas de aprendizado de máquina kNN, PCA e Autoencoder e as suas aplicações em distintos detectores de risco de quedas. Em seguida, detalha-se o procedimento empregado para o tratamento dos dados de CSI pelos detectores. Por fim, apresentam-se as métricas usadas para a avaliação do desempenho como acurácia, sensibilidade e especificidade.

No Capítulo 3, são dispostas as implementações de detectores de risco de queda baseados em kNN, PCA e Autoencoder, bem como resultados e análises para a detecção de amostras de CSI com anomalias.

No último capítulo, são apresentadas as conclusões do trabalho, com a indicação do algoritmo de aprendizado de máquina de melhor desempenho na detecção de amostras com risco de queda. Ademais, são delineadas direções de trabalhos futuros que podem ser seguidas a partir dos resultados deste estudo.

Além disso, esta dissertação inclui Apêndices com detalhes adicionais sobre o padrão IEEE 802.11, a técnica OFDM, o dispositivo ESP32 e com o desempenho dos três detectores de risco baseados em kNN, PCA e Autoencoder para avaliar amostras de CSI com anomalias, distribuídas em conjuntos com situações específicas de risco de queda, como, por exemplo, amostras medidas quando o voluntário caminha pelo ambiente.

1 FUNDAMENTAÇÃO

Como apresentado na Introdução, o objetivo deste trabalho é implementar um detector de risco de queda para ambiente hospitalar, extraindo da rede local sem fio a informação do estado do canal ou CSI. O monitoramento através da CSI é efetuado pela análise de detecção de mudanças nas condições de propagação do sinal. Esta técnica permite o acompanhamento de mudanças no ambiente com equipamentos Wi-Fi apenas, sem a necessidade de dispositivos inteligentes ou de filmagem.

Neste capítulo, são discutidos alguns trabalhos que aplicam a técnica CSI para fins similares, bem como fundamentos sobre a CSI. As próximas seções descrevem o padrão IEEE 802.11 para as redes locais sem fio das quais obtém-se a CSI. Em seguida, é demonstrada a técnica de transmissão de dados OFDM empregada nas redes locais sem fio e na última seção é apresentada a visão geral da CSI.

1.1 Trabalhos Relacionados

O FILA (*Fine-grained Indoor Localization*) é um sistema proposto por Wu et al. [17] que se beneficia da CSI para mitigar o efeito de multipercurso no receptor. O sistema é implementado em NICs (*Network Interface Card*) 802.11 comerciais e, em seguida, é avaliado o seu desempenho em diferentes cenários típicos de interiores. Os resultados experimentais demonstram que a precisão e a latência do cálculo da distância podem ser aperfeiçoados através da CSI. Além disso, o FILA pode melhorar significativamente a precisão da localização em comparação com a abordagem RSSI.

O sistema proposto por Xiao et al., [9], o Pilot (*Passive Device-free Indoor Localization Using Channel State Information*) visa a localização interna a partir da CSI. O Pilot realiza um mapa de rádio passivo da área de interesse que inclui registros únicos (chamados impressões digitais/*fingerprints*) para entidades localizadas em posições de referência. Para esse fim, é projetado um bloco de detecção de anomalias para reconhecer a aparência da área de interesse como o gatilho de localização que depende da mudança da CSI. Posteriormente um algoritmo probabilístico é proposto para comparar a CSI anormal com aquelas no banco de dados (impressões digitais) e estimar as posições de potenciais entidades existentes. Por fim, um novo bloco de fusão de dados é desenvolvido para abordar a localização de múltiplas entidades no ambiente.

O CARM (*CSI based human Activity Recognition and Monitoring system*) é um sistema apresentado por Wang et al. [18]. O sistema realiza o reconhecimento e monitoramento de atividades humanas baseado em CSI. Para o experimento, o sistema consiste em dois dispositivos Wi-Fi comerciais, com um roteador que atua como transmissor enviando sinais continuamente para um laptop, que atua como receptor. O CARM reconhece a atividade humana conforme as mudanças nos valores da CSI usando um modelo CSI-velocidade e um modelo CSI-atividade. Por meio desses dois modelos é analisada a dinâmica do valor CSI, a velocidade de movimento humano, as velocidades de movimento das diferentes partes do corpo humano e uma atividade humana específica. O CARM usa essa correlação como mecanismo para a criação de perfil e o reconhecimento de uma determinada atividade. Os autores relatam uma precisão média de 96% para o reconhecimento de atividade, já em um ambiente e usuário desconhecidos, o CARM alcança a precisão de cerca de 80%.

Um sistema para monitoramento de queda de idosos em ambiente internos é proposto por Dias et al. [19]. O sistema pode ser introduzido em hospitais, asilos ou lares de idosos com rapidez e baixo custo. O monitoramento é realizado usando um acelerômetro embutido e o local onde ocorreu a queda é identificado usando transceptores Zigbee (padrão IEEE 802.15.4). A detecção e identificação de quedas apresenta bons resultados com acurácia superior a 90%.

O sistema WiDMove apresentado por Silva et al. [11] é uma proposta para a detecção de entrada e saída de pessoas em ambientes fechados utilizando CSI. O WiDMove é baseado em técnicas de processamento de sinais e de aprendizado de máquina como PCA (*Principal Component Analysis*), FFT (*Fast Fourier Transform*), STFT (*Short-Time Fourier Transform*), e emprega validação cruzada com k-Fold e com Leave-One-Out, que permite extrair e classificar eventos com as medidas da CSI, com acurácia média superior a 85%.

Uma plataforma IoT para detectar-se a ocupação em tempo real através da CSI foi proposto por Yang et al. [20]. A plataforma usa roteadores Wi-Fi comerciais prontos para coletar a CSI. Com a plataforma é possível realizar a detecção de ocupação a partir de curvas das subportadoras CSI na presença humana. A plataforma obtém uma precisão de 96,8% e 90,6% em termos detecção e reconhecimento de ocupação, respectivamente.

Em [1] Fang et al.propõeuma abordagem baseada em aprendizagem profunda apli-

cando Redes Neurais Profundas (DNN -*Deep Neural Networks*) e técnicas de aprendizado de máquina como SVM (*Support Vector Machine*), DT (*Decision Trees*) e GMM (*Gaussian Mixture Models*) a parâmetros de sinais sem fio para o monitoramento de atividades humanas como ausência, presença e sonolência em ambiente de trabalho. As diferentes técnicas são comparadas e obtém-se a precisão em torno de 93%.

1.2 **IEEE 802.11**

O IEEE 802.11 compreende uma série de padrões e protocolos que descrevem o Controle de Acesso ao Meio (MAC - *Medium Access Control*) e Camada Física (PHY - *Physical Layer*) para redes locais sem fio WLANs. Na Tabela 1, estão listados os principais padrões do IEEE 802.11 e suas características.

Tabela 1: Padrões IEEE 802.11. [5, 21–24]

Padrões 802.11	**Características**
a (Original)	Define um padrão WLAN que inclui as funções MAC e PHY
a	Define um suplemento PHY de alta velocidade (até 54Mbps) na banda de 5 GHz
b	Define uma extensão PHY de alta velocidade (até 11 Mbps) na banda de 2,4 GHz
d	Melhora do 802.11 original para suportar QoS. Operação em domínios regulatórios adicionais
e	Aprimora o MAC 802.11 original para suportar QoS (aplica-se a 802.11 a/b/g)
f	Define uma prática recomendada para o protocolo de ponto de inter-acesso (aplica-se a 802.11 a/b/g)
g	Define uma extensão PHY de taxa mais alta (até 54 Mbps) na banda de 2,4 GHz
h	Define funções MAC que permitem que produtos 802.11 a atendam aos requisitos regulatórios europeus
i	Aprimora 802.11 MAC para fornecer melhoria na segurança (aplica-se a 802.11 a/b/g)
j	Aprimora os atuais 802.11 MAC e 802.11 a PHY para operar nas bandas japonesas de 4,9 GHz e 5 GHz
k	Fornece informações para a escolha do melhor AP disponível que garanta o QoS necessário.
n	Aprimora o 802.11 ae 802.11 PHY para operar em taxas de dados de até 600 Mbps
p	Modifica o padrão 802.11 a para comunicações veiculares
r	Padroniza o hand-off rápido quando um cliente wireless estiver se locomovendo de um ponto de acesso para outro na mesma rede
s	Fornece um protocolo para autoconfiguração de redes *mesh*
t	Provê métodos de medida, de métricas de desempenho, e de recomendações que permitem fabricantes, laboratórios independentes de teste, fornecedores de serviço,extremidade - usuários para medir o desempenho do equipamento e de redes padrão 802.11.
v	Permitir a configuração de dispositivos clientes conectados a redes 802.11. O padrão pode incluir paradigmas de gerência similares aos utilizados em redes celulares
w	Fornece integridade e autenticação de dados de quadros da camada física.
z	Habilita o equipamento Wi-Fi para operar em frequência entre 3650-3700MHz somente nos EUA.
ac	Padrão opera em faixa de 5GHz, com taxas de até 1 Gbps.
ad	Desenvolvido para aumentar significativamente a velocidade transmitindo o sinal a 60 GHz e taxas de dados de cerca de 7 Gbps. Na maior frequência, entretanto, seu alcance é limitado a cerca de 10 metros, limitando o uso dos dispositivos 802.11ad em um único ambiente.
af	Define especificações internacionais para compartilhamento de espectro entre dispositivos de espaço em branco não licenciados (WSDs - *White Space Devices*) e serviços licenciados na banda de espaço em branco da TV.
ah	Permite o acesso sem fio usando frequências de subportadoras abaixo de 1 GHz na banda ISM (industrial, científica e médica) e permite que os dispositivos habilitados para Wi-Fi obtenham acesso garantido para transmissões de dados de curta duração.
ax	Aproveita os pontos fortes do 802.11ac e adiciona flexibilidade e permite que as redes existentes e as novas tenham mais capacidade para aplicativos de última geração. Possibilita maior velocidade na faixa de gigabit e melhor desempenho para novas aplicações. Apresenta compatibilidade com versões anteriores com dispositivos 802.11a/g/n/ac.

O modelo OSI (*Open Systems Interconnection*) é um sistema de referência da ISO - Organização Internacional de Padronização (*International Organization for Standardization*) - cujo objetivo é padronizar/descrever protocolos de redes de comunicações. Esse modelo divide a rede em camadas para o envio e recepção de mensagens. Na Figura 4, apresenta-se a comparação entre os modelos IEEE 802.11 e OSI. O modelo de referência IEEE 802 é baseado no modelo de referência OSI. A camada PHY do modelo 802.11 é equivalente à camada Física do modelo OSI e as subcamadas MAC e LLC (*Logical Link Control*) do IEEE 802.2, à camada de Enlace do modelo OSI. As camadas PHY e MAC fazem parte do modelo IEEE 802.11 e a camada LLC ao modelo IEEE 802.2.

O 802.11 é necessário para atender camadas superiores como a subcamada LLC [25], cuja função é receber os dados do protocolo da camada superior, montar o quadro com a informação de qual protocolo é responsável por gerar os dados e envio do quadro para a camada MAC [26].

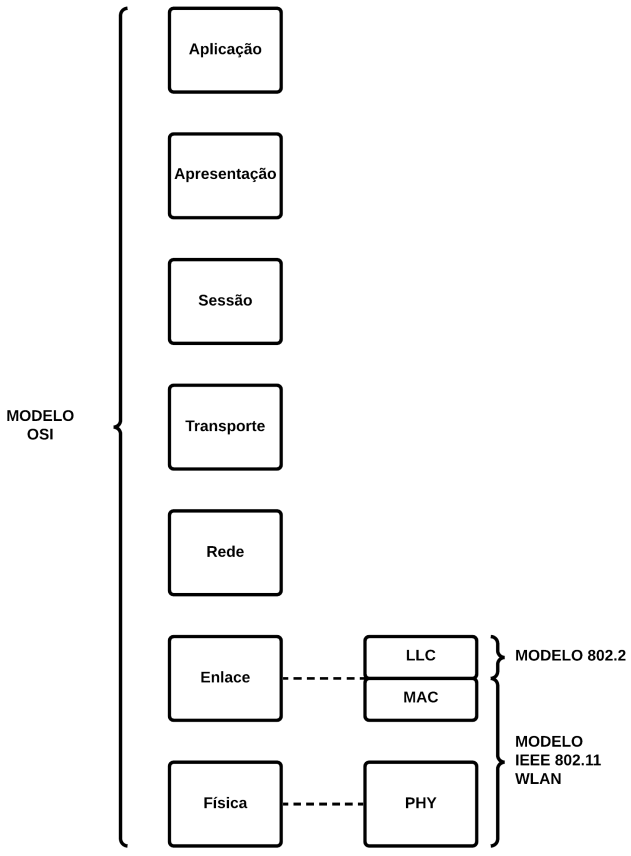

Figura 4: Modelos de Referência OSI e IEEE 802.11.

Uma das funções camada PHY do modelo IEEE 802.11 é a codificação e decodi-

ficação de sinais para transmissão e recepção das mensagens. Na camada PHY, o IEEE 802.11 define uma série de padrões de transmissão e codificação para comunicações sem fio, os mais comuns: FHSS (*Frequency Hopping Spread Spectrum*), DSSS (*Direct Sequence Spread Spectrum*), CCK (*Complementary Code Keying*), SDM (*Spatial Division Multiplexing*), MU-MIMO (*Multi-User Multiple-Input Multiple-Output*) e OFDM (*Orthogonal Frequency Division Multiplexing*) como apresentado na Tabela 2.

Tabela 2: - Padrões da camada PHY do IEEE 802.11 [27].

	802.11	**802.11 *b***	**802.11 *a***	**802.11 *g***	**802.11 *n***	**802.11 *ac***
Tecnologia PHY	DSSS	DSSS/CCK	OFDM	OFDM DSSS/CCK	SDM/OFDM	SDM/OFDM MU-MIMO
Faixa de Frequência (GHz)	2.4	2.4	5	2.4	2.4 e 5	5
Largura de banda (MHz)	25	25	20	25	20 e 40	20, 40, 80 e 160
Taxa de dados (Mbps)	1, 2	5.5, 11	6 - 54	1 - 54	6.5 - 600	6.5-6933.3

Os padrões IEEE 802.11 *a/g/n* empregam OFDM, em que, a Informação do Estado do Canal (CSI) fornece estimativas das amplitudes e fases da função de transferência do canal em cada subportadora.

1.2.1 IEEE 802.11*a*

O padrão 802.11*a* surgiu concomitantemente ao padrão 802.11*b*, porém não chegou ao mercado simultaneamente. O padrão 802.11*a* tinha como principais vantagens a maior taxa de transmissão e a maior imunidade a interferências - ocasionadas principalmente por outros dispositivos na faixa ISM (*Instrumentation, Scientific and Measurement* – não licenciada) em 2,4 GHz, como, por exemplo: telefones sem fio e micro-ondas.

O padrão IEEE 802.11*a* pode atingir taxas de até 54 Mbps, operando na banda de frequência em torno de 5 GHz, empregando o OFDM com 64 subportadoras. No entanto, somente 52 das 64 subportadoras carregam informação, enquanto as restantes não carregam informação útil. Dessas 52 subportadoras, 4 são usadas como pilotos modulados em BPSK (*Binary Phase-Shift Keying*) por uma sequência pseudo-aleatória, e as outras 48 subportadoras transportam dados, nas quais se pode empregar constelações BPSK, QPSK (*Quadrature Phase-Shift Keying*), 16-QAM (16 símbolos - *Quadrature Amplitude Modulation*) ou 64-QAM (64 símbolos -*Quadrature Amplitude Modulation*) [5].

1.2.2 IEEE 802.11g

O padrão foi disponibilizado em 2003, considerado o "sucessor natural" do padrão 802.11b sendo retro-compatível.

O IEEE 802.11g opera a taxas de até 54 Mbps, utilizando OFDM na faixa de frequências em torno de 2,4 GHz. Por ser compatível com o padrão 802.11b, possibilita operar também conforme o 802.11b usando DSSS. Os adaptadores 802.11g podem conectara um AP 802.11b e adaptadores 802.11b podem conectar-se a um AP 802.11g. Assim, o 802.11g fornece uma opção de *upgrade* ou migração para redes 802.11b, acomodando dispositivos legados e novos na mesma faixa de frequência de operação.

1.2.3 IEEE 802.11n

O padrão IEEE 802.11n permite estender as taxas de dados da camada física além daquelas dos padrões do IEEE 802.11a/g.

O padrão 802.11n oferece altas taxas com objetivo de aumento de velocidade e de banda para suportar serviços como HDTV (*High Definition Television*), VoD (*Video on Demand*) e prover meios que permitam a interoperabilidade desse novo padrão com as tecnologias antecessoras. O padrão n incorporou a tecnologia de antenas de múltiplas entradas e saídas (MIMO - *Multiple Input, Multiple Output*) [28].

A aprovação do padrão IEEE 802.11n aconteceu em 2009. Um dos requisitos no desenvolvimento do padrão 802.11n era que alguns modos de operação fossem compatíveis com os 802.11a e g tal que a interoperabilidade ocorresse na camada física. Para tal fim, definiu-se um preâmbulo obrigatório, sendo uma sequência de bits que os receptores procuram para estabelecer o modo de operação, de Formato Misto (MF) no padrão 802.11n [27].

Implementaram-se mudanças nas camadas MAC e PHY, permitindo velocidades até 600 Mbps, utilizando modulação 64-QAM. As alterações realizadas na camada física definiram a operação dos padrões 802.11a/g em canais de 20 MHz de largura de banda; para o padrão 802.11n, introduziu-se a possibilidade de canais de 40 MHz e, além disso, há a possibilidade de que 2 canais adjacentes (sem superposição) de 20 MHz sejam combinados para formar um único canal de 40 MHz. Deste modo, os canais podem ser configurados com 20 MHz, 40 MHz ou conversão automática de 40/20 MHz. Os canais com conversão

automática operam em 40 MHz, mas podem automaticamente retornar para 20MHz, na presença de interferências [27].

Opera-se na faixa de 2,4 GHz em canais de 20 MHz de largura de banda e, em 5 GHz, os canais podem ser designados com 40 MHz, permitindo atingir velocidades de 600 Mbps.

Enquanto os padrões 802.11*a/g* podiam prover taxas de até 54 Mbps, dividindo cada canal de 20 MHz em 52 subportadoras com capacidade de até 1,038 Mbps cada, no padrão 802.11*n* o mesmo canal de 20 MHz é dividido em 56 portadoras com a mesma taxa individual, aumentando a taxa de transferência total. Empregando canais de 40 MHz, o 802.11*n* suporta até 114 subportadoras, oferecendo maior taxa de transferência [5].

1.2.4 IEEE 802.11*ac*

Em 2007, durante o desenvolvimento do padrão IEEE 802.11*n*, iniciou-se um novo grupo de trabalho (o grupo de estudo VHTT – *Very High Throughput*) para lançar uma rede ainda mais rápida, relativa ao IEEE 802.11*ac*, visando velocidades superiores aos 600 Mbps do padrão IEEE 802.11*n* [29]. O padrão foi publicado em 2013.

O IEEE 802.11*ac* é uma evolução do IEEE 802.11*n* e, em vez de usar MIMO apenas para aumentar o número de fluxos de dados enviados a um único cliente, disponibiliza uma forma de MIMO multiusuário que permite que um AP envie dados para vários clientes em simultâneo [29]. Com a capacidade de transmissão em alta velocidade para vários dispositivos simultaneamente, o IEEE 802.11*ac* permite redes mais rápidas.

Além disso, o IEEE 802.11*ac* apresenta duas novas larguras de banda, 80 MHz e 160 MHz, e há duas formas de uso de canais de 160 MHz: em único bloco de 160 MHz ou em dois blocos de 80 MHz que combina dois canais 80 MHz e oferece a mesma capacidade, funcionando na banda de 5GHz [29].

A Figura 5 mostra a comparação entre as subportadoras OFDM dos padrões 802.11*a, g, n* e *ac*. Cada linha representa um tipo de canal e suas subportadoras OFDM. As quedas simbolizam as subportadoras piloto. A primeira linha representa os padrões 802.11*a* e *g* com canais de 20 MHz. A segunda linha o padrão 802.11*n* quando utiliza canais de 20MHz e a terceira linha canais de 40 MHz. A quarta e quinta linhas representam o padrão 802.11*ac* com canais de 80 MHz ou 160 MHz respectivamente [29].

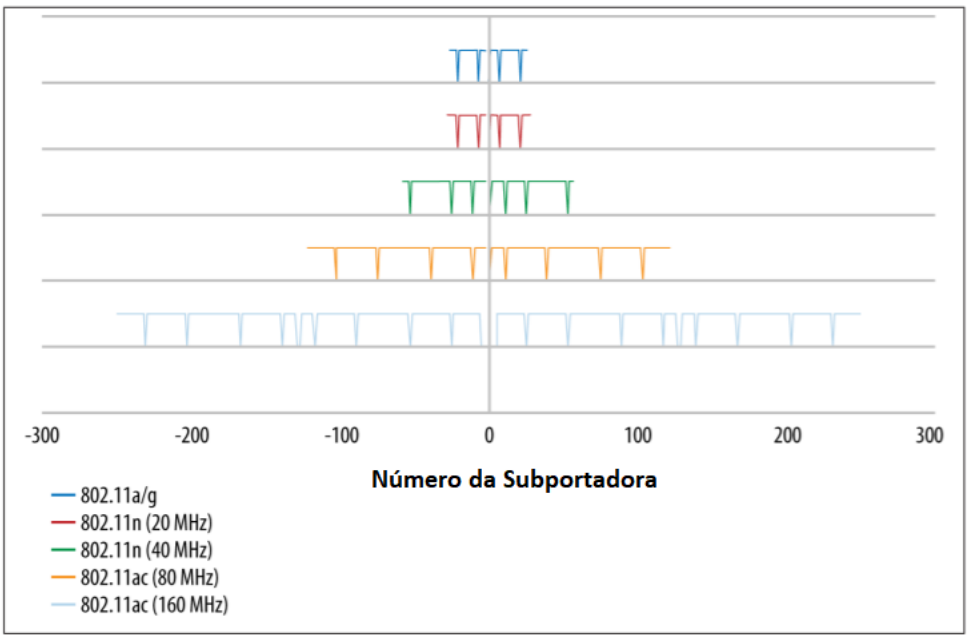

Figura 5: Canais de dados OFDM no padrão IEEE 802.11 [29].

1.2.5 Cabeçalho e Preâmbulo

Um dos requisitos funcionais no desenvolvimento do padrão 802.11n é que os modos de operação deveriam ser compatíveis com as versões anteriores – 802.11a e 802.11g. Ainda, o grupo de desenvolvimento do padrão 802.11n também decidiu que a interoperabilidade deveria ocorrer na camada física [27].

A camada PHY consiste em duas subcamadas: PLCP (Procedimento de Convergência da Camada Física - *Physical Layer Convergence Procedure*) e a PMD (Dependente do Meio Física - *Physical Medium Dependent*).

A subcamada PMD é encarregada pelas técnicas de transmissão, modulação e codificação do sinal como responsável pelo envio e recebimento de pacotes no meio. A subcamada PLCP é a interface entre a camada de enlace e a camada física, pois entrega as informações recebidas da PMD à subcamada MAC e possui o preâmbulo [5].

Existem três categorias de preâmbulos PLCP usados para a sincronização e a estimativa do canal. A Figura 6 apresenta as categorias de preâmbulo na camada PHY.
Preâmbulo Legado: É idêntico ao preâmbulo 802.11a e deve ser usado apenas se dispositivos legados (802.11a) forem usados em um determinado momento [5].
Preâmbulo de Formato Misto(MF): Usado se os dispositivos 802.11a e n estiverem presentes da rede LAN. Este preâmbulo irá garantir compatibilidade entre as versões dos

padrões IEEE 802.11*a, g* e *n*. Possui os mesmos campos do preâmbulo legado, seguidos do campo HT-SIG (*High Throughput-Signal*) que contém informações sobre parâmetros MIMO e alocações de banda exclusivos de dispositivos 802.11*n* [5].

Preâmbulo de Formato de Alto Desempenho(HT): Utilizado se houver apenas dispositivos 802.11*n*, que omite os campos de Modo Legado, fornecendo um preâmbulo mais curto e eficiente [5].

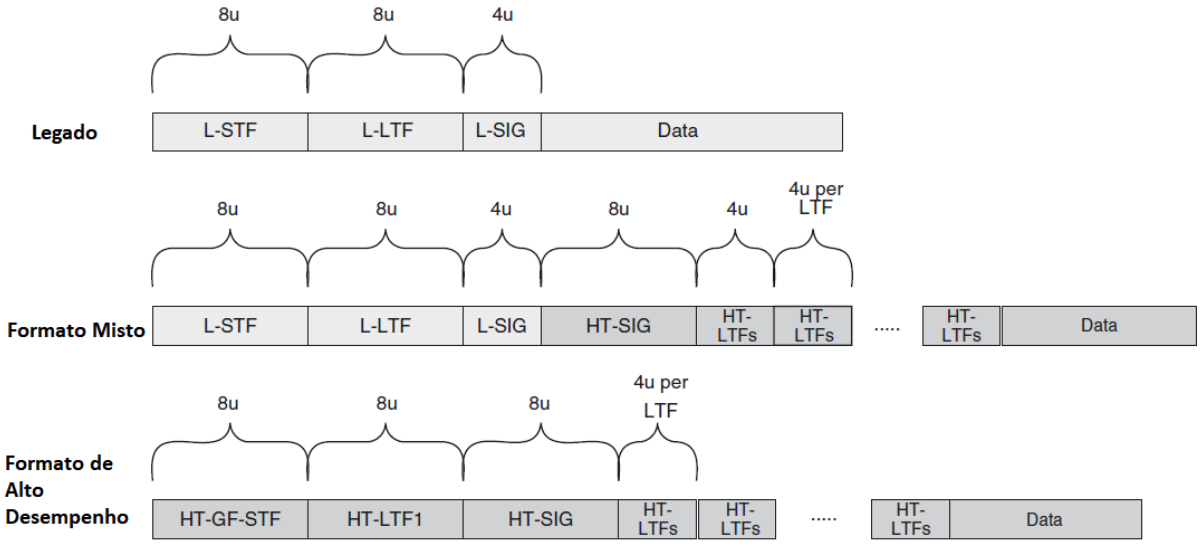

Figura 6: Categorias de preâmbulos 802.11*n*. Adaptado de [5].

Neste trabalho, são empregadas subportadoras L-LTF(*Legacy - Long Training Field*) e HT-LTF (*High Throughput - Long Training Field*), disponíveis nos Preâmbulos Legado e de Formato Misto. Em função disso, serão detalhados os Preâmbulos Legado e Formato Misto.

Neste capítulo, são detalhados os campos dos preâmbulos que contém informações sobre subportadoras e estimativa do canal. Os outros campos dos Preâmbulos de Legado e Formato Misto estão disponíveis no Apêndice A.1.

O padrão 802.11*a* possui os campos LTF disponíveis no seu preâmbulo apresentados na Figura 7.

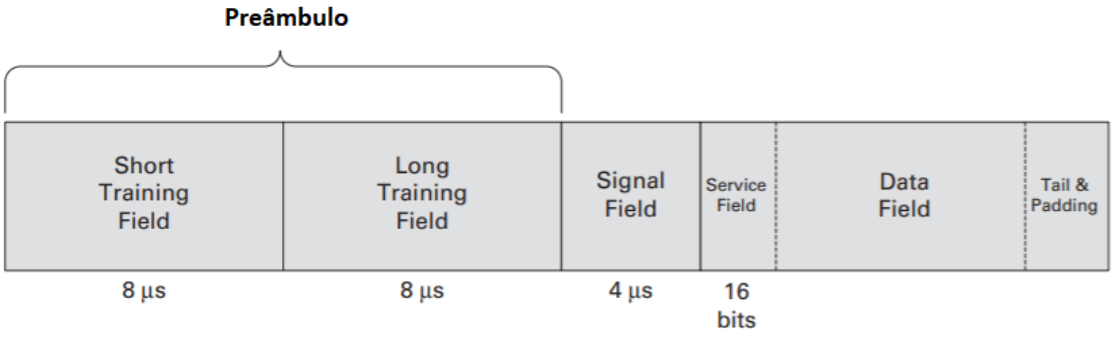

Figura 7: Estrutura do pacote 802.11*a*. Adaptado de [27].

O LTF é usado para estimativa de canal e para estimativas de deslocamento de frequência e de sincronização de tempo mais precisas. Esse campo possui 8 μs de duração sendo composto por dois símbolos de treinamento de 3,2 μs precedidos por um prefixo cíclico de 1,6μs [27]. No LTF, há informações sobre as subportadoras como:

a) Os índices das subportadoras variam de -32 a 31 e as preenchidas com dados estão entre -26 e -1, 1 e 26 [27].

b) Quatro das subportadoras são dedicadas a sinais piloto para tornar a detecção coerente robusta contra desvios de frequência e ruído de fase. Os sinais piloto devem ser colocados nas subportadoras -21, -7, 7 e 21 [25].

c) A subportadora DC (*frequência zero*), L_0, não é preenchida [27].

d) Todas as subportadoras preenchidas têm o valor +1 ou -1.

$$L_{-26,26} = 1,1,-1,-1,1,1,-1,1,-1,1,1,1,1,1,1,-1,-1,1,1,-1,1,-1,1,1,1,1,0,1,$$
$$-1,-1,1,1,-1,1,-1,-1,-1,-1,-1,1,1,-1,-1,1,-1,1,-1,1,1,1,1 \quad (1.1)$$

O padrão 802.11*n* emprega a estrutura de pacotes de formato misto apresentada na Figura 8.

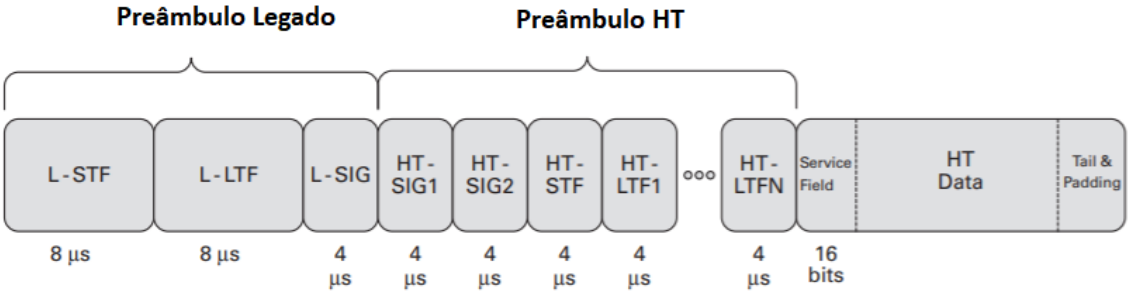

Figura 8: Estrutura do pacote Preâmbulo de Formato Misto. Adaptado de [27].

O preâmbulo de formato misto (MF) é composto por campos legados semelhantes ao 802.11*a* e formatos de alto rendimento (HT), e pode ser usado com larguras de canal de 20 MHz ou 40 MHz. Os campos legados garantem compatibilidade com versões anteriores de 802.11*a* e *g*. Estes são seguidos por campos do preâmbulo HT. A Figura 8 mostra o exemplo do preâmbulo MF para o canal de largura de 20MHz.

O preâmbulo HT compreende os próximos 20 μs, com os campos HT-SIG (*High Throughput Signal*), HT-STF (*High Throughput Short Training*) e HT-LTF (*High Throughput Long Training*). Os dois símbolos OFDM do HT-SIG contêm informações de sinalização e também são usados para autodetecção entre pacotes dos preâmbulos HT e de Legado. Dos campos disponíveis neste preâmbulo, os HT-LTFs são usados para estimativa de canal MIMO e possuem as seguintes informações:

a) O HT-LTF para operação de 20 MHz é definido com base na sequência de domínio de frequência dada pela Eq. (1.2). Esta sequência é uma extensão do símbolo de L-LTF da Eq. (1.1), com duas subportadoras adicionais, -28 e -27 preenchidas com +1 e duas subportadoras adicionais, 27 e 28, preenchidas com -1 [27]:

$$\begin{aligned} L_{-28,28} = {} & 1,1,1,1,-1,-1,1,1,-1,1,-1,1,1,1,1,1,1,-1,-1,1, \\ & 1,-1,1,-1,1,1,1,1,0,1,-1,-1,1,1,-1,1,-1,-1, \\ & -1,-1,-1,1,1,-1,-1,1,-1,1,-1,1,1,1,1,-1,-1 \end{aligned} \tag{1.2}$$

b) As subportadoras piloto estão localizadas nas mesmas subportadoras que em 802.11 *a*, ou seja, -21, -7, 7 e 21 [27].

1.3 OFDM - *Orthogonal Frequency Division Multiplexing*

OFDM é uma técnica de transmissão de dados utilizada em TV digital, redes 4G e redes Wi-Fi, entre outros. Nesta técnica, a banda de transmissão é dividida em múltiplas sub-bandas através de portadoras ortogonais, chamadas subportadoras. A condição de ortogonalidade faz com que as subportadoras não interfiram entre si.

A OFDM é uma variante da Multiplexação por Divisão de Frequência (FDM - *Frequency Division Multiplexing*) usada nos sistemas de telefonia e nas tecnologias de redes de acesso como a ADSL (*Assymetrical Digital Subscriber Line*) e nas redes *wireless*. Em um sistema FDM, as portadoras estão suficientemente espaçadas de modo que os canais de diferentes bandas possam ser separados utilizando filtros passa-banda convencionais. Entretanto, em geral, para tornar a separação possível, bandas de guarda têm que ser introduzidas entre essas portadoras, o que resulta em uma diminuição da eficiência espectral.

No OFDM, em vez de bandas de guarda entre subportadoras, essas são sobrepostas, resultando em um ganho espectral de até de 50% em relação à técnica FDM, como mostrado na Figura 9.

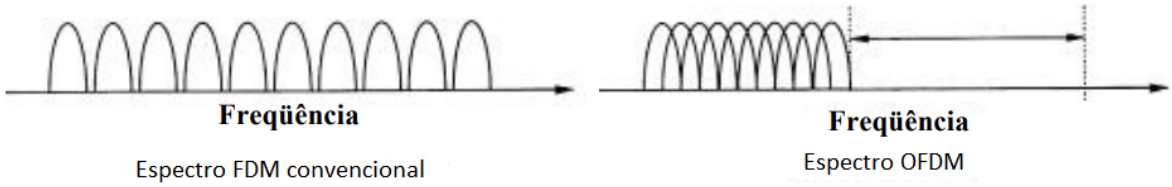

Figura 9: FDM e OFDM [30].

No OFDM, definem-se as subportadoras de forma que na frequência de uma subportadora (máximo de seu espectro) coincidam os zeros de outras subportadoras, como mostra a Figura 10.

Além disso, inserindo um intervalo de tempo de guarda entre os símbolos sucessivos, a propagação multi-percurso não causa interferência inter-simbólica (réplicas atrasadas do sinal causando distorção no sinal recebido). O Apêndice A.2 descreve como o OFDM satisfaz o Primeiro Critério de Nyquist para ISI nula.

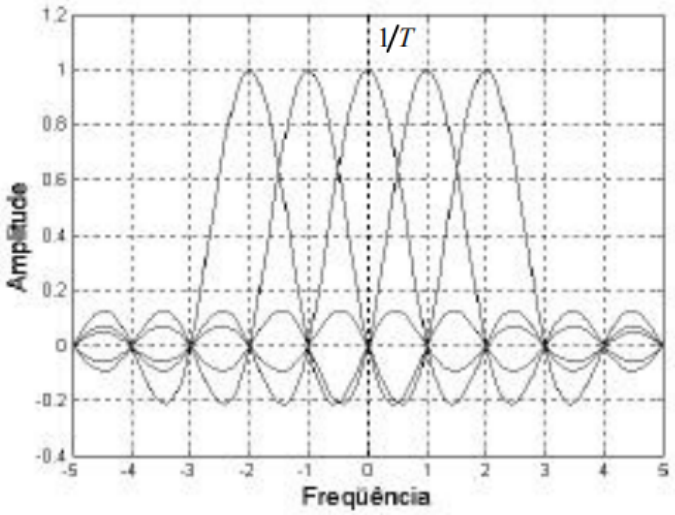

Figura 10: OFDM com subportadoras [30].

A Figura 11 mostra o diagrama de blocos básico de um sistema de comunicação OFDM. Os dados de entrada seriais são paralelizados para transmissão através das K subportadoras simultaneamente. A largura de banda do canal W é subdividida igualmente em subcanais de largura de banda suficientemente estreita W/K, de modo que na banda de frequência de cada subcanal, a resposta de frequência é constante tanto em magnitude como em fase [31].

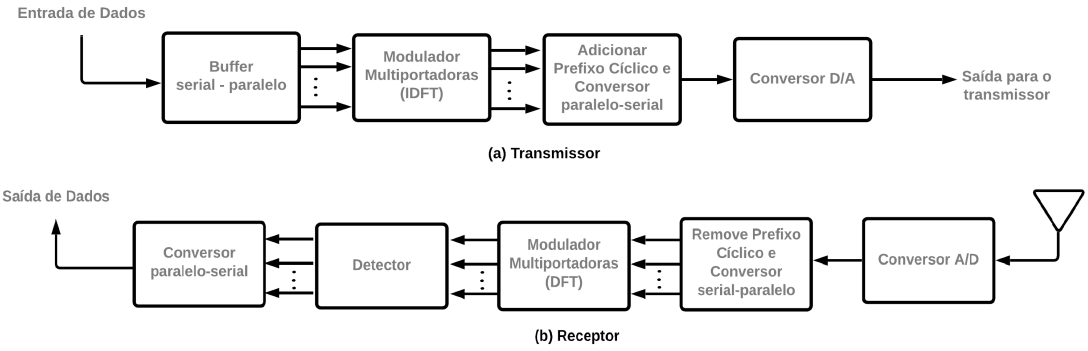

Figura 11: Diagrama de bloco de um sistema de comunicação digital multiportadora OFDM [31].

São realizados K subcanais, em que K símbolos do canal são transmitidos simultaneamente. A taxa de símbolo é $1/T$ em cada um dos subcanais, igual à separação de frequência entre as subportadoras adjacentes. Assim, os sinais transmitidos nos K canais são ortogonais ao longo do intervalo de símbolo T [31].

O uso da Transformada Discreta Inversa de Fourier (IDFT - *Inverse Discrete Fourier Transform*) impõe ortogonalidade entre as K subportadoras. No transmissor, IDFT é implementada eficientemente usando o algoritmo de Transformada Inversa Rápida de Fourier (IFFT - *Inverse Fast Fourier Transform*). As amostras de sinal modulado em tempo discreto da IFFT passam por um conversor Digital/Analógico (D/A) para produzir um sinal de tempo contínuo que é transmitido através do canal [31].

No receptor, o sinal recebido sofre um processamento inverso. Primeiramente, ele é digitalizado por um conversor Analógico/Digital (A/D) e as amostras do conversor são enviadas ao demodulador. As amostras do sinal correspondem, idealmente, à IDFT dos sinal que contém os símbolos comportados pelas subportadoras. Assim, o demodulador computa a DFT (*Discrete Fourier Transform*) dessas amostras para recuperar os símbolos das K subportadoras. Como no transmissor, a DFT é calculada eficientemente empregando o algoritmo da Transformada Rápida de Fourier (FFT - *Fast Fourier Transform*) [31].

Para compensar o efeito do canal nos símbolos transportados em cada subcanal, é necessário medir a magnitude e a mudança de fase do canal em cada subportadora. Tal medição é obtida pela transmissão de sinais piloto embutidos no sinal OFDM [31].

A Figura 11 ainda possui um bloco de Prefixo Cíclico na implementação FFT do modulador e demodulador. O Prefixo Cíclico tem como finalidade inserir um intervalo de guarda para eliminar a ISI entre símbolos OFDM sucessivos.

Um símbolo OFDM de duração T_{OFDM} é constituído pela informação útil do símbolo de duração T e pelo intervalo de guarda T_g. Com a adição do intervalo de guarda, o símbolo OFDM resulta em [32]:

$$T_{OFDM} = T + T_g \tag{1.3}$$

No transmissor, após o bloco IFFT, são inseridas amostras de prefixo cíclico e no receptor essas amostras são descartadas na entrada do demodulador FFT. Deste modo, qualquer dispersão de tempo produzida pelo canal no sinal é eliminada [31]. Mais informações sobre sistemas OFDM e Prefixo Cíclico são apresentadas no Apêndice A.2.

A seguir, é descrito como um sistema OFDM empregando uma constelação QAM, como observado na Figura 11(a), obtém o sinal transmitido.

O *buffer* serial-paralelo subdivide um fluxo de informações em bits B_f. Os bits B_f em cada quadro são analisados em K grupos, onde ao i-ésimo grupo é atribuído b_i

bits [31]. Consequentemente,

$$\sum_{i=0}^{K-1} b_i = B_f \tag{1.4}$$

O modulador multiportadoras gera K subcanais QAM independentes, onde cada canal terá símbolo $1/T$ (onde T é a duração do símbolo) e o sinal em cada subcanal tem uma constelação QAM distinta [31].

O número de pontos do i-ésimo subcanal é $M_i = 2^{b_i}$. Os pontos de valor complexo correspondente aos sinais de informação nos K subcanais são representados por X_k, onde $k = 0, 1, \ldots, K\text{-}1$ [31].

Os símbolos de informação X_k representam os valores da DFT de um sinal $x(t)$ que é um sinal OFDM de multiportadora, com modulação QAM em cada subportadora. Dado que $x(t)$ é um sinal de valor real, os N-pontos da DFT X_k devem satisfazer a propriedade de simetria Hermitiana $X_{N-k} = X_k^*$. Portanto, são criados $N = 2K$ símbolos a partir de K símbolos de informação, definidos por [31]:

$$\begin{aligned} X_{N-k} &= X_k^*, \quad k = 1, 2, ..., K-1 \\ &\text{com } X_0^{'} = \mathrm{Re}[X_0], \text{ e } X_K = \mathrm{Im}[X_0]. \end{aligned} \tag{1.5}$$

O símbolo de informação X_0 é dividido em duas partes, $X_0^{'}$ e X_K. Se denotarmos a nova sequência de símbolo $X_k^{'}$ com $k = 0, 1, \ldots, N\text{-}1$, a IDFT de N pontos resulta na sequência de valor real

$$X_n = \frac{1}{\sqrt{N}} \sum_{k=0}^{N-1} X_k^{'} e^{j2\pi nk/N} \tag{1.6}$$

$$= \frac{1}{\sqrt{N}} \left[\mathrm{Re}[X_0] + (-1)^n \mathrm{Im}[X_0] + 2 \sum_{k=1}^{K-1} \cos\left(\frac{2\pi nk}{N} + \theta_k \right) \right] \tag{1.7}$$

com $n = 0, 1, \ldots, N\text{-}1$ e o símbolo da informação $X_K = \mid X_k \mid e^{j\theta_k}$.

A sequência $X_n,\ 0 \leq n \leq N-1$, corresponde a amostras de $x(t)$, sinal OFDM, que consiste em K subportadoras de frequência $f_k = k/T$, com $k = 0, 1, 2, \ldots, K\text{-}1$ [31].

O símbolo X_0 corresponde a componente DC, $f_0 = 0$. Por conveniência, é definido $X_0 = 0$, de forma que o sinal OFDM não tenha componente DC. Em seguida, o sinal

OFDM transmitido, após a passagem através de um conversor digital para analógico (D/A), é representado por [31]

$$x(t) = \frac{2}{\sqrt{N}} \sum_{k=1}^{K-1} \mid X_k \mid \cos\left(\frac{2\pi kt}{T} + \theta_k\right), \qquad 0 \leq t \leq T \tag{1.8}$$

A principal vantagem do uso de OFDM em relação à técnica que utiliza uma única portadora é que ela pode obter a mesma taxa de transferência, devido ao paralelismo de subportadoras de taxas baixas, com maior resistência a condições ruins do meio, como atenuação de altas frequências, interferência inter-simbólica, e interferência causada por múltiplos caminhos, frequente em redes sem fio.

1.4 **CSI - *Channel State Information***

A CSI representa a estimativa do canal sem fio, sendo obtida em sistemas sem fio como as redes com padrão IEEE 802.11n, que empregam a técnica OFDM , onde a transmissão de dados é realizada dividindo a banda em subportadoras ortogonais. Com o OFDM, cada subportadora transmite dados em diferentes frequências simultaneamente o que permite se estimar a resposta do canal sem fio a partir de cada subportadora. O uso do OFDM confere resistência a condições ruins do meio como a propagação multipercurso.

A CSI quantifica a resposta do canal sem fio por meio de valores de amplitude e fase de cada subportadora, descrevendo como o sinal se propaga no meio entre o transmissor e o receptor. A presença de pessoas e objetos no ambiente interno e efeitos combinados de espalhamento e desvanecimento [17] alteram o valor de amplitude e fase de cada subportadora.

1.4.1 Formato da CSI

A CSI é obtida em redes WLAN, seus valores são fornecidos pela interface de rede e caracterizam a resposta do canal para cada subportadora entre cada par de antenas de transmissão-recepção. Com a CSI é possível revelar como um sinal se propaga sob os efeitos devido ao ambiente interno, como o espalhamento ou o desvanecimento. Em um canal de desvanecimento plano de banda estreita, o sistema OFDM no domínio da

frequência é modelado como [17]

$$\mathbf{y} = \mathbf{H}\mathbf{x} + \mathbf{n}, \tag{1.9}$$

onde $\mathbf{x}$ representa o vetor do transmissor, $\mathbf{y}$ é o vetor do receptor, $\mathbf{H}$ a matriz do canal e $\mathbf{n}$ o vetor de ruído gaussiano branco aditivo (AWGN).

A resposta em frequência do canal de uma subportadora é dada por:

$$h = |h|e^{j\,\sin(\angle h)}, \tag{1.10}$$

onde a $|h|$ representa a amplitude e $\angle h$ representa a fase de cada subportadora.

Portanto, espera-se que a movimentação de objetos e pessoas no ambiente produzam alterações de percursos entre transmissores e receptores e consequentemente alterações na CSI.

A Figura 12 mostra os possíveis efeitos de obstrução que resultam em alterações da CSI. A Figura 12(a) apresenta um enlace em linha de visada direta que corresponde a um canal com poucas imperfeições. Na Figura 12(b), a linha de visada é obstruída, ocorrendo a dispersão do sinal por multi-percursos e a recepção de sinais refletidos e, consequentemente, a CSI correspondente é outra. Os valores da CSI das diferentes subportadoras podem derivar de variados caminhos, e, em cada subportadora, temos diferentes valores de amplitude e fase, dependente de cada situação.

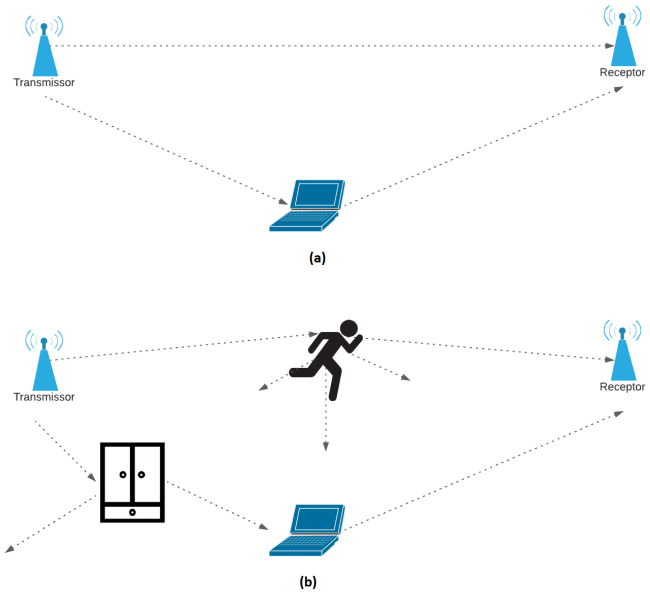

Figura 12: Representação do ambiente sem obstrução (a) e com obstrução (b) do sinal.

Acompanhando mudanças no canal sem fio a partir da CSI, neste trabalho implementam-se detectores de risco de queda para pacientes hospitalizados, com o emprego apenas de dispositivos de rede sem fio Wi-Fi.

Para detectar a situação de anormalidade nas amostras de CSI são aplicados três sistemas distintos para detecção de risco de queda baseado nos algoritmos de aprendizado de máquina: kNN, PCA e Autoencoder. No próximo capítulo, detalham-se a metodologia para coleta da CSI, os algoritmos de aprendizado de máquina usados para o sistema de detecção de risco de quedas e as métricas para avaliação do desempenho de cada detector.

2 METODOLOGIA DO PROJETO

Este capítulo tem como finalidade detalhar as etapas do projeto do detector de risco de queda a partir de amostras da CSI. No capítulo anterior, foram apresentados os fundamentos de redes Wi-Fi, OFDM, o que é a CSI e sua disponibilidade em redes Wi-Fi.

A metodologia está divida em:

1. **Configuração do microcontrolador:** Usamos o módulo ESP32 (maiores detalhes no Apêndice A.3) com programação em C++. Na configuração, definem-se parâmetros como os canais e os dispositivos da rede Wi-Fi dos quais serão coletadas a CSI e a taxa de repetição em que as amostras serão capturadas.

2. **Captura e tratamento da CSI:** Planejamos um ambiente para realização de testes e identificação das situações alvo para coleta das amostras CSI. Também foram elaborados *scripts* na linguagem de programação Python para o processamento das amostras da CSI coletadas, organização das amostras, além do cálculo de amplitude e fase de cada subportadora.

3. **Aprendizado de máquina**: Nesta etapa realiza-se o treinamento dos detectores de risco de queda baseados em kNN, PCA ou Autoencoder. Foram utilizadas bibliotecas Python para os algoritmos de aprendizado de máquina.

4. **Detecção do risco de queda:** Realizamos os testes e a avaliação dos sistemas projetados/treinados através de curvas ROC (*Receiver Operating Characteristic Curve*) e métricas como acurácia, sensibilidade e especificidade para se avaliar o desempenho dos detectores de risco de queda.

2.1 Configuração do Microcontrolador

Neste projeto, foram utilizados dois módulos ESP32. O ESP32 é considerado um dispositivo de baixo custo para aplicações de IoT que suporta dispositivos de Wi-Fi nos padrões IEEE 802.11*a/g/n*. No Apêndice A.3 deste trabalho, estão disponíveis informações adicionais sobre este dispositivo. A Figura 13 mostra o esquema dos dispositivos usados neste estudo.

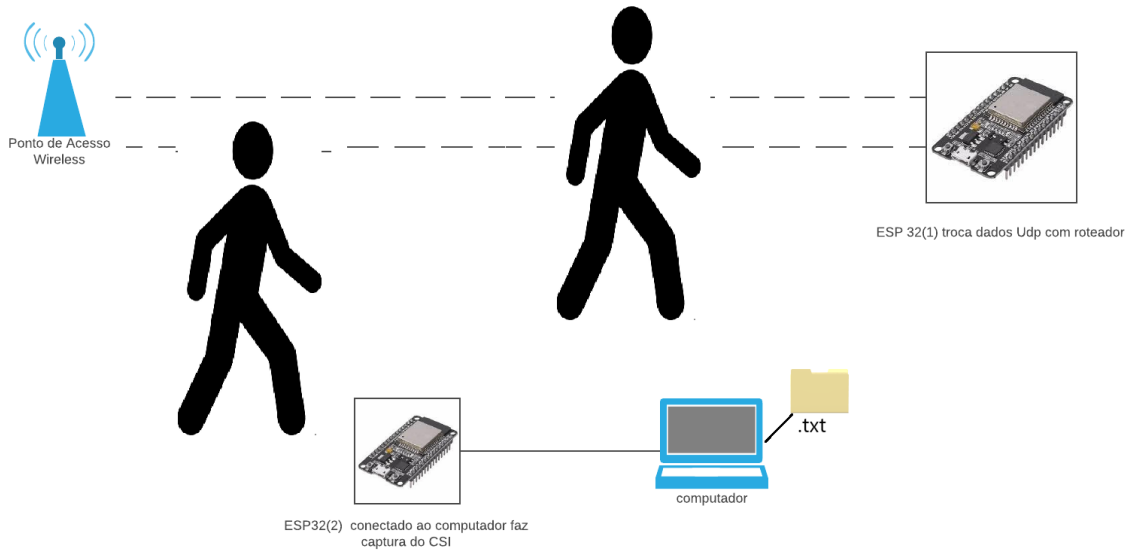

Figura 13: - Esquema de monitoramento CSI.

O primeiro módulo ESP32 é configurado para a coleta da CSI do ambiente de teste. O módulo ESP32 é programado em C++, com parâmetros necessários para coleta da CSI. Algumas das configurações são:

a) Escolher os dispositivos sem fio dos quais se coleta a CSI. Através do endereços MAC (da camada de acesso ao meio), escolhe-se tais dispositivos.

b) Especificar do preâmbulo dos quadros do padrão IEEE 802.11 para requisição e coleta apenas das subportadoras LLTF e HT-LTF, mencionados no Capítulo 1, da CSI dessas redes.

c) Determinar o canal sem fio a ser monitorado. É o canal em que opera o ponto de acesso *wireless* do ambiente de testes. No Brasil, a Anatel (Agência Nacional de Telecomunicações) permite que as redes locais sem fio na banda de 2,4 GHz utilizem até 11 canais com 20 MHz cada.

d) Definir a frequência de coleta dos dados pelo microcontrolador. Na configuração aplicada a este projeto, são capturadas 2 amostras de CSI por segundo.

O segundo módulo ESP32 é configurado para trocar informações com um computador que funciona na mesma rede do ambiente de testes. A partir da comunicação desses dispositivos, será capturada a CSI do segundo módulo ESP32.

É aplicada uma configuração no segundo módulo ESP32 para que as mensagens trocadas com o computador sejam realizadas através do protocolo de comunicação UDP (*User Datagram Protocol*), que funciona na camada de transporte e possibilita o envio de informações de forma rápida.

O computador que recebe as mensagens UDP do segundo módulo ESP32 é um notebook com sistema operacional Windows 10 para uso residencial ou comercial conectado a mesma rede sem fio a qual o microcontrolador ESP32 é monitorado. Ambos estão conectados a um roteador de uso residencial/comercial da fabricante do Qualcomm Atheros Communications Inc., que trabalha com protocolo 802.11n e banda de 2,4GHz, sem a necessidade de configurações adicionais para a coleta da CSI. A rede sem fio a que o computador e o segundo módulo ESP32 estão conectados possuem as configurações apresentadas na Figura 14.

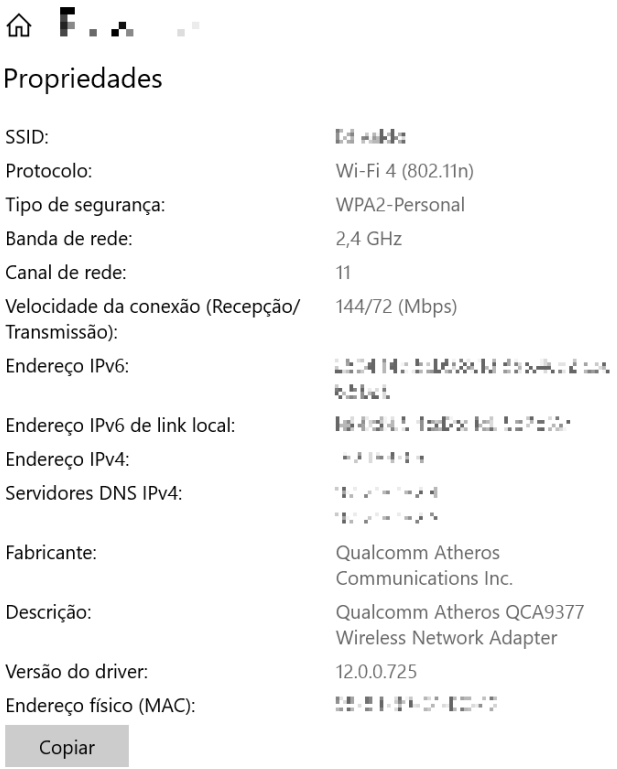

Figura 14: Configurações do Ponto de Acesso Wireless no ambiente de teste.

Após a configuração dos módulos ESP32, o próximo passo é preparar um computador, que atua como servidor de dados, para o armazenamento das amostras de CSI capturadas pelo primeiro módulo ESP32. A comunicação entre o servidor de dados e o

primeiro módulo ESP32 é realizada através de uma porta micro USB (*Universal Serial Bus*). É preparado um *script* na linguagem de programação Python para o armazenamento das amostras CSI em arquivos de texto (.txt) que posteriormente serão analisadas pelos detectores de queda baseados em algoritmos de aprendizado de máquina.

2.2 Captura da CSI

A CSI capturada pelo ESP32 possui valores reais e imaginários de cada subportadora, e a sequência das subportadoras não é ordenada corretamente. Por esse motivo, é necessário o tratamento dos arquivos de texto com as amostras de CSI com o objetivo de ordenar as subportadoras e calcular a amplitude e fase de cada uma.

A seguir são apresentadas as etapas para a captura e o tratamento da CSI:

a) Foram coletadas as subportadoras de L-LTF com índices -32 a 31 e HT-LTF -32 a 31.

b) O módulo ESP32 coleta a CSI, com os valores imaginários e reais de cada subportadora.

c) O módulo ESP32 é configurado para realizar a coleta de duas amostras da CSI por segundo.

A Tabela 3 mostra o resumo da CSI capturada pelo módulo ESP32:

Tabela 3: Dados das amostras da CSI coletados [33].

Modo do sinal	HT
Largura de banda do canal	20 MHz
Índices das Subportadoras	
L-LTF	0 a 31, -32 a -1
HT-LTF	0 a 31, -32 a -1

2.2.1 Tratamento dos dados CSI

Como descrito na Seção 2.2, a CSI coletada é composta por valores complexos correspondentes às subportadoras L-LTF e HT-LTF de índices 0 a 31 e -32 a -1. Primeiro, é preciso organizar as subportadoras L-LTF e HT-LTF com seu índice em ordem crescente de -32 a 31. Como as amostras da CSI são apresentadas com números complexos, calculam-se os valores de amplitude e fase das subportadoras.

Alguns estudos que empregam a CSI [11,20] recomendam o emprego da amplitude das subportadoras em detrimento da fase. A CSI recebe informações de deslocamento de fase do sinal, mas esses dados obtidos por equipamentos convencionais são imprecisos devido a imperfeições nos componentes eletrônicos e a dessincronização dos dispositivos. O problema é conhecido como CFO (*Carrier Frequency Offset*), que torna a métrica da fase não confiável para o reconhecimento de atividades [11]. A presença de ruído de fase e o assincronismo entre moduladores e demoduladores pode gerar CFO prejudicando a ortogonalidade do subcanal e afetando o desempenho do sistema [34].

Seguindo a maioria dos estudos de CSI, a detecção do risco de queda será realizada através da amplitude das subportadoras. Deste modo, os algoritmos de aprendizado de máquina para a avaliação de detecção de anormalidades são treinados usando a amplitude das subportadoras. A Figura 15 mostra a amplitude das subportadoras obtida através da CSI.

	LLTF_-32	...	LLTF_-27	LLTF_-26	LLTF_-25	...	HTLTF_25	HTLTF_26	HTLTF_27	...	HTLTF_31
0	0	...	5.000000	17.888544	17.888544	...	32.802439	33.015148	32.756679	...	1.000000
1	0	...	5.830952	20.591260	21.023796	...	40.816663	41.182521	41.146081	...	1.000000
2	0	...	4.000000	19.026298	19.104973	...	34.058773	34.234486	34.525353	...	2.236068
3	0	...	4.472136	19.697716	19.697716	...	18.027756	17.492856	4.472136	...	0.000000
4	0	...	4.242641	19.798990	19.849433	...	38.013156	38.288379	38.897301	...	1.414214
..	...	...	...	...	...	...	...	...	...	...	...
195	0	...	4.472136	19.235384	20.248457	...	44.777226	45.276926	45.276926	...	2.236068
196	0	...	5.000000	20.000000	19.416488	...	47.707442	47.010637	48.301139	...	2.000000
197	0	...	5.000000	21.633308	21.095023	...	47.423623	46.238512	45.221676	...	2.236068
198	0	...	5.000000	22.203603	22.472205	...	43.829214	43.863424	43.081318	...	2.236068
199	0	...	5.830952	21.470911	21.954498	...	50.596443	52.000000	52.773099	...	1.000000

Figura 15: Amplitude das Subportadoras OFDM (CSI).

2.2.2 Área monitorada

A captura da CSI foi realizada em um ambiente de testes simulando uma enfermaria/ambiente hospitalar. O ambiente de testes é um quarto com $9m^2$ de área e mobiliado. Nesse ambiente, há um roteador instalado. A Figura 16 mostra a planta baixa do ambiente com as localizações da mobília, dos microcontroladores ESP32 e do ponto de acesso wireless.

O microcontrolador apresentado na Figura 16 como ESP32(1) é monitorado e tem a CSI capturada pelo ESP32(2). O ESP32(1) envia dados (UDP) para um *desktop* conectado na mesma rede. As amostras da CSI são armazenadas em um servidor de dados (computador) conectado ao ESP32(2) através da conexão micro USB do microcontrolador.

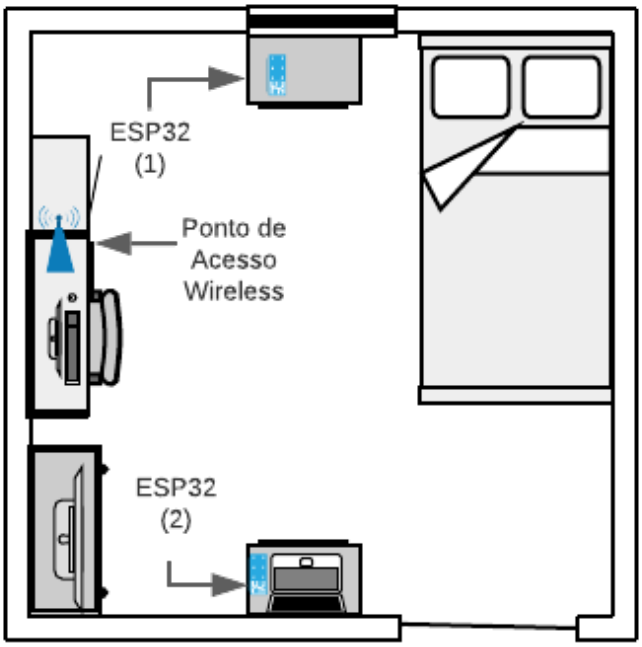

Figura 16: Local do monitoramento CSI.

2.2.3 Descrição do experimento

Com objetivo de avaliar variações na CSI, foram simuladas situações de risco de queda no ambiente de testes com o auxílio de um voluntário. Enquanto os dispositivos que compõem a rede sem fio no ambiente de testes trocam informações, foram simulados dois cenários para a captura da CSI:

a) Sem risco de queda - o voluntário permanece deitado na cama colocada no ambiente de testes (um quarto).

b) Com risco de queda - o voluntário levanta da cama, caminha, corre ou simula uma queda, movimentos que diferem da situação "Sem risco de queda".

A Figura 17 ilustra as situações "Sem risco de queda" e "Com risco de queda" no ambiente de testes.

Na configuração mostrada na Figura 17, o ESP32(1) está localizado a 1 metro de distância da cama onde o voluntário simulou o cenário "Sem risco de queda".

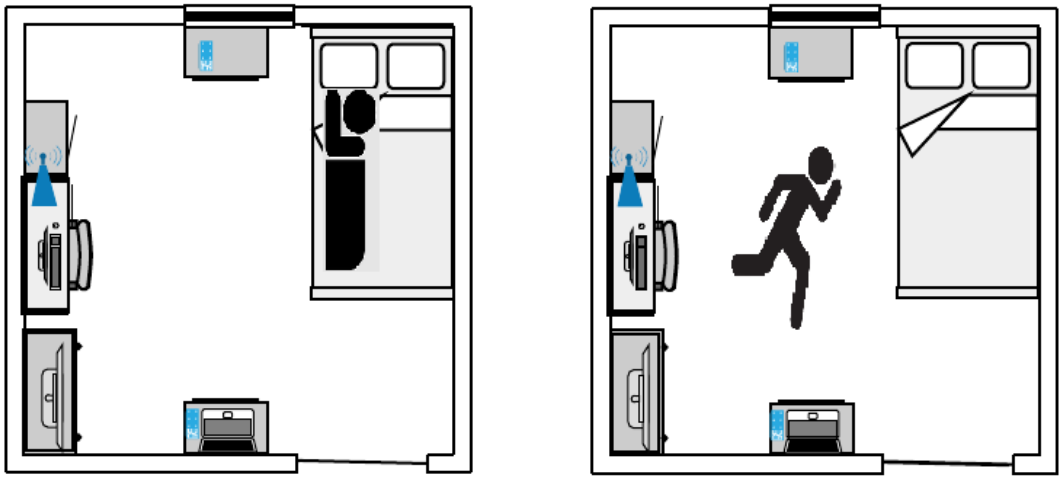

Figura 17: (a) Sem risco de queda (b) Com risco de queda.

São capturadas 3000 amostras de CSI no cenário "Sem risco de queda", que serão divididas por métodos de validação *Hold-out* ou validação cruzada *k-Fold*, para treino (80% - 2400 registros) e testes (20% - 600 registros). Em seguida, são efetuados treinamentos de cada algoritmo de aprendizado de máquina para o sistema de detecção de risco de queda.

No cenário "Com risco de queda", são capturadas amostras de CSI distríbuidas em conjuntos com 600 amostras cada. Essas amostras serão analisadas posteriormente pelos detectores de risco de queda conjuntamente as amostras de testes (600 registros) do cenário "Sem risco de queda".

2.3 **Aprendizado de máquina para avaliar o sistema desenvolvido**

Aprendizado de Máquina (*Machine Learning*) é área de inteligência artificial que tem o objetivo de desenvolver técnicas computacionais para construir, armazenar e reconhecer padrões de forma automática. Um sistema de aprendizado de máquina tem a capacidade da tomada de decisões fundamentadas em soluções de problemas analisados anteriormente. Os sistemas de aprendizado de máquina podem ser classificados quanto à linguagem de descrição, paradigma, modo e forma de aprendizado [35].

A Figura 18 ilustra diferentes modalidades de aprendizado de máquina dividido em aprendizado supervisionado e não supervisionado. No aprendizado supervisionado, os recursos estão associados a um rótulo e o algoritmo aprende a classificar de acordo com suas medidas [36]. Os problemas de aprendizagem supervisionada são classificados em regressão e classificação. Nos problemas de regressão, os algoritmos tentam prever os resultados de uma saída contínua, mapeando as variáveis de entrada por meio de uma função contínua, enquanto nos problemas de classificação, os algoritmos preveem os resultados em uma saída discreta [37].

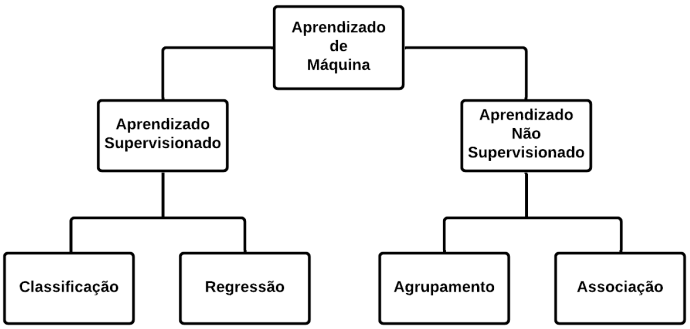

Figura 18: Representação das modalidades de aprendizado de máquina.

No aprendizado não-supervisionado, o conjunto de dados não é rotulado, os algoritmos aprendem propriedades da estrutura dos dados para desempenhar funções como o agrupamento, dividindo os dados em grupos semelhantes [36].

2.3.1 Aprendizado Supervisionado e Aprendizado não Supervisionado

No aprendizado supervisionado, é fornecido ao algoritmo de aprendizado, um conjunto de exemplos de treinamento para os quais os rótulos das classes correspondentes são conhecidos. Em geral, cada exemplo é descrito por um vetor de valores de características e rótulo da classe associada. O objetivo do algoritmo supervisionado é construir um classificador com o qual novos dados possam ser atribuídos a uma classe [35]. Os algoritmos de classificação visam identificar a classe à qual pertence determinado vetor de valores de características. Os algoritmos de regressão tem como objetivo prever um valor numérico para uma entrada dada.

No aprendizado não supervisionado, os rótulos são desconhecidos e os algoritmos não fazem o uso de atributos de saída. O aprendizado não supervisionado pode ser de

agrupamento ou associação. No algoritmo por agrupamento, são reunidas as amostras com outras semelhantes. Os agrupamentos segmentam os registros dos dados em subconjuntos ou *clusters*, de forma que os elementos de um *cluster* compartilham propriedades comuns e ao mesmo tempo diferentes das características de outros *clusters* [38]. O algoritmo de associação visa identificar correlações e conjuntos que seguem as mesmas regras.

Os algoritmos não supervisionados são usados mais frequentemente em ambientes exploratórios com o objetivo de entender melhor um conjunto de dados. Os algoritmos não supervisionados também podem ser usados como uma etapa de pré-processamento para os algoritmos supervisionados. Aprender uma nova representação dos dados pode melhorar a precisão dos algoritmos supervisionados ou levar a uma redução do consumo de memória e tempo [39].

Dos diversos algoritmos de aprendizado de máquina, os que foram empregados no detector de risco de queda são descritos a seguir: o kNN, a PCA e o Autoencoder.

2.3.2 kNN - *k-Nearest Neighbors Algorithm*

kNN é o algoritmo de k-vizinhos mais próximos. É considerado um dos métodos de classificação mais simples, pois a classificação é efetuada observando os k exemplos contidos no conjunto de treinamento que sejam mais próximos ao padrão de entrada a classificar. Para isso, define-se uma medida de distância entre os padrões. Dentre os k exemplos semelhantes, o alvo mais popular (votação por maioria) é escolhido como rótulo de classificação.

A Figura 19 mostra um exemplo de classificação por kNN que recebe um novo dado não-classificado (ponto preto). Em seguida, é determinada a menor distância entre o novo dado e os dados já classificados como pertencentes as classes A (pontos amarelos) e B (pontos vermelhos), valor que depende de k. Neste exemplo, quando é escolhido um valor de k igual a 3, os três vizinhos mais próximos incluem mais pontos da classe A, então o novo dado é classificado como da Classe A, mas quando é escolhido o valor de k igual a 6, aparecem mais pontos vermelhos, logo o novo dado é classificado como da Classe B.

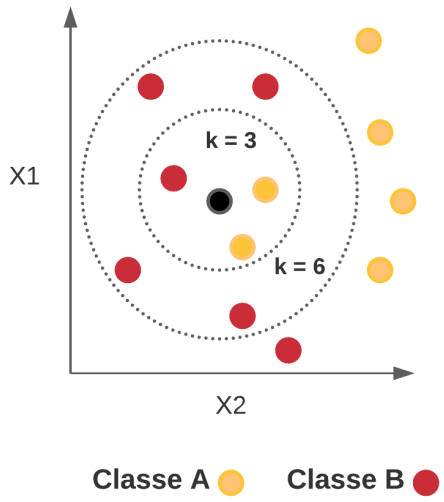

Figura 19: Representação de kNN com dois rótulos de classe e para diferentes valores de k.

A distância Euclidiana entre dois pontos ou vetores $\mathbf{x} = [x_1, x_2, \ldots, x_N]$ e $\mathbf{y} = [y_1, y_2, \ldots, y_N]$ do espaço $\mathbb{R}^N$ é dada por:

$$d = \sqrt{\sum_{n=1}^{N} (x_n - y_n)^2}. \tag{2.1}$$

Algumas aplicações empregam a distância de "Manhattan" (ou soma de valores absolutos),

$$d = \sum_{n=1}^{N} |x_n - y_n|. \tag{2.2}$$

Ambas são casos particulares da norma de ordem p (Minkowski),

$$d_p(\mathbf{x}, \mathbf{y}) = \left(\sum_{n=1}^{N} |x_n - y_n|^p \right)^{\frac{1}{p}}, \tag{2.3}$$

que para a distância Euclidiana é $d_2(\mathbf{x}, \mathbf{y})$ e a de Manhattan é $d_1(\mathbf{x}, \mathbf{y})$.

A escolha de k é um fator importante, pois se k for um valor muito baixo, o algoritmo se tornará muito flexível e sobre-dimensionado aos dados (*Overfitting*). Se k for muito alto, o kNN se tornará inflexível, traçando um limite muito rígido e inadequado aos dados (*Underfitting*) [40].

O sobre-ajuste (*Overfitting*) ocorre quando um modelo é ajustado para as particu-

laridades do conjunto de treinamento e obtém-se um modelo excelente para determinado conjunto de treinamento, mas que não é eficiente para novos dados. Por sua vez, o subajuste (*Underfitting*) ocorre quando o modelo é muito simples e não captura os aspectos e a variabilidade dos dados, apresentando um desempenho ruim mesmo no conjunto de treinamento [39].

2.3.3 PCA - *Principal Component Analysis*

A Análise de Componentes Principais ou PCA é um algoritmo de redução de dimensionalidade que projeta os dados de entrada num espaço de dimensão reduzida. O PCA produz combinações lineares das variáveis originais para gerar os eixos, também conhecidos como componentes principais [41]. Um conjunto de dados com muitas variáveis, como, por exemplo, as amostras CSI nas quais cada subportadora define uma coordenada, pode-se aplicar a redução de dimensionalidade.

O PCA projeta os vetores de entrada num espaço alternativo, isto é, obtém combinações lineares (ou seja, rotações) dos vetores de entrada. Tais combinações definem novos vetores por meio de uma transformação linear. Após a rotação do espaço, o primeiro vetor do conjunto de saída contém a maior parte da energia do sinal. O segundo é ortogonal ao primeiro e contém a maior parte da energia restante; o terceiro é ortogonal aos primeiros dois vetores e contém a maior parte da energia restante, e assim por diante [42]. A base "de saída" é ortogonal e permite decompor e sintetizar uma versão aproximada do vetor de entrada usando menos vetores base. A quantidade de vetores base usados depende da concentração de energia obtida.

O conjunto de n amostras com m variáveis/coordenadas permite construir a matriz de dados $\mathbf{X}_{n\times m}$:

$$\mathbf{X} = \begin{bmatrix} x_{11} & \dots & x_{1m} \\ \vdots & \ddots & \vdots \\ x_{n1} & \cdots & x_{nm} \end{bmatrix} \tag{2.4}$$

e para obter as componentes principais, seja um conjunto de m variáveis X_1, X_2, ..., X_m, com média μ_1, μ_2, ..., μ_m e variância σ_1^2, σ_2^2, ..., σ_m^2. As variáveis não são descorrelacionadas, portanto, possuem covariância entre a i-ésima e a k-ésima variáveis σ_{ik} para $i \neq k = 1, 2, \dots, m$ [43].

As m variáveis podem ser expressas como vetor aleatório $\mathbf{x} = [x_1, x_2, \ldots, x_m]^T$, com média $\mu_{\mathbf{X}} = [\mu_1, \mu_2, \ldots, \mu_m]^T$ e a matriz de covariância $\mathbf{\Sigma}$ é dada por [43]:

$$\mathbf{\Sigma} = \begin{bmatrix} \sigma_{11}^2 & \cdots & \sigma_{1n}^2 \\ \vdots & \ddots & \vdots \\ \sigma_{n1}^2 & \cdots & \sigma_{nn}^2 \end{bmatrix}. \tag{2.5}$$

A partir da matriz de covariância $\mathbf{\Sigma}$ obtém-se os autovalores e autovetores. Os autovalores são encontrados com o cálculo das raízes do polinômio característico:

$$\det(\mathbf{\Sigma} - \lambda \mathbf{I}) = 0, \tag{2.6}$$

onde $\mathbf{I}$ é a matriz identidade, cujos elementos da diagonal principal são iguais a 1 e os outros elementos iguais a 0.

Os autovetores associados a cada autovalor são encontrados a partir de:

$$(\mathbf{\Sigma} - \lambda \mathbf{I})\mathbf{a} = (\mathbf{\Sigma} - \lambda \mathbf{I}) \begin{bmatrix} a_1 \\ \vdots \\ a_m \end{bmatrix} = 0, \tag{2.7}$$

onde $\mathbf{a}$ são chamados autovetores da matriz $\mathbf{\Sigma}$.

Os pares de autovalores e autovetores $(\lambda_1, \mathbf{a}_1),\ (\lambda_2, \mathbf{a}_2),\ \ldots,\ (\lambda_m, \mathbf{a}_m)$ ordenados tais que $\lambda_1 \geq \lambda_2 \geq \ldots \lambda_m$ e associados a $\mathbf{\Sigma}$ definem as componentes principais de $\mathbf{X}$ [43].

Com o cálculo dos autovetores da matriz de covariância é possível identificar as características para uma melhor representação dos dados pela ordenação decrescente dos autovetores de acordo com seus autovalores. O autovetor associado ao maior autovalor corresponde a componente principal do conjunto de dados. O autovetor com o segundo maior autovalor corresponde a segunda componente principal, e assim sucessivamente [44].

A primeira componente principal ($\mathbf{y}_1$) é a dada pela combinação linear das variáveis $[X_1, X_2, \ldots, X_m]$ [41, 43],

$$\mathbf{y}_1 = a_{11}X_1 + a_{12}X_2 + ... + a_{1m}X_m, \tag{2.8}$$

ou em notação matricial,

$$\mathbf{Y_1} = \mathbf{a}_1^T \mathbf{X}, \tag{2.9}$$

sendo calculada para ser responsável pela maior variação possível no conjunto de dados. A variância da primeira componente principal é obtida projetando-se o vetor de entrada sobre $\mathbf{Y}_1$, o que dependerá dos coeficientes de $\mathbf{a}_1 = [a_{11},\ a_{12},\ \ldots, a_{1m}]$, com a restrição que a soma dos quadrados seja igual a 1 e, assim [41],

$$\| \mathbf{a}_1 \|^2 = \sqrt{a_{11}^2 + a_{12}^2 + ... + a_{1m}^2} = 1. \tag{2.10}$$

A segunda componente principal é calculada da mesma forma, com a condição de que não esteja correlacionada com a componente principal, ou seja, deve ser na direção de maior variância [41] e perpendicular à primeira componente. Assim,

$$\mathbf{Y}_2 = a_{21}X_1 + a_{22}X_2 + ... + a_{2m}X_m \tag{2.11}$$

Procede-se assim até que as m componentes principais tenham sido calculadas com o mesmo número variáveis originais. A variância total será a soma da diagonal de $\mathbf{\Sigma}$ igual ao $\mathbf{tr}(\mathbf{\Sigma})$. As transformações dos vetores originais nos componentes principais são obtidas por [41],

$$\mathbf{Y} = \mathbf{AX} \tag{2.12}$$

com $\mathbf{Y}$ igual as componentes principais, $\mathbf{X}$ igual às variáveis originais e a matriz $\mathbf{A}$ são chamadas de autovetores da matriz $\mathbf{\Sigma_x}$, a matriz de variância-covariância dos dados originais.

Os autovalores representam as variâncias explicadas por cada componente principal, e apresentam ordem decrescente de magnitude da primeira componente até a última componente principal. Os autovalores são comumente apresentados em um gráfico que apresenta nas abcissas o número das componentes principais e nas ordenadas o autovalor correspondente, mostrando a taxa decrescente de variância das componentes [41]. A Figura 20 mostra o gráfico da variância explicada da CSI de 128 componentes principais e pode-se determinar a quantidade de componentes principais importantes para a

representação dos dados.

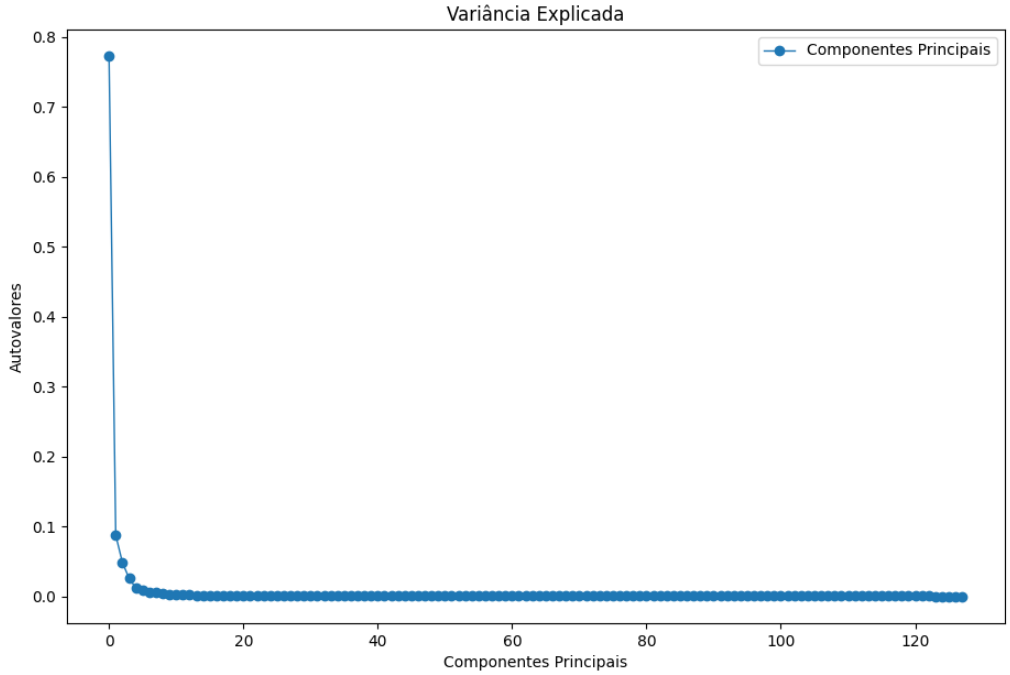

Figura 20: Gráfico da Variação Explicada para cada componente principal CSI.

Como o PCA permite a redução da dimensionalidade, um conjunto de dados com muitas variáveis pode ser reduzido em algumas componentes principais. Alguns critérios são utilizados para determinar a quantidade de componentes principais e obter a melhor representação do conjunto de dados como, ignorar as componentes principais no ponto que a próxima componente ofereça pouco acréscimo na variância total, ou o uso de componentes principais até se que atinja, por exemplo, 90% de sua variância [41].

Uma alternativa para se obter o PCA, envolve a técnica de Decomposição de Valores Singulares (SVD - *Singular Value Decomposition*). A SVD é uma técnica de fatoração de uma matriz qualquer em três outras matrizes com características específicas. Possui aplicações tanto diretas através de resultados extraídos a partir de suas matrizes de decomposição, quanto em conjunto com a PCA. A PCA possui elevado custo computacional para conjuntos de dados muito grandes, com muitas variáveis, pela necessidade do cálculo de autovalores e autovetores da matriz de covariância. A SVD é uma alternativa viável para encontrar os autovalores e autovetores [45].

2.3.4 Autoencoder

O Autoencoder é uma categoria de redes neurais em camadas que possui a capacidade de redução de dimensionalidade não-linear, e tem sido utilizado desde a década de 1990 [46].

O Autoencoder é classificado como uma rede *feedforward* ou MLPs (*Multi Layer Perceptrons*), sendo considerado uma rede neural que pode profunda (*Deep Learning*) ou não. A maioria dos sistemas de aprendizado profundo são redes neurais artificiais com várias camadas ocultas empilhadas e não há conexões de *feedback* em que as saídas do modelo são realimentadas [36].

No Autoencoder, os dados são representados por redes neurais, compostas por uma camada de entrada, várias camadas ocultas e uma camada de saída [47]. Pode ser empregado para diversos fins, como a detecção de anomalias, pré-treinamento de redes de aprendizagem profunda, a eliminação de ruído de imagens e áudio, compressão e classificação, como o exemplo disponível em [48]. Neste trabalho é aplicado um Autoencoder para a detecção de anomalias.

A camada de entrada do Autoencoder recebe os dados originais e a camada de saída os reconstrói. As camadas ocultas atuam como uma hierarquia que compreende como a camada anterior funciona e como se relaciona com a camada de saída. Através dessa hierarquia, a rede neural consegue aprender conceitos complicados, construindo-os a partir de outros mais simples [47].

Os principais componentes do Autoencoder são um codificador e um decodificador. O codificador reduz a dimensionalidade de um conjunto de dados de alta dimensão para um conjunto de dados de baixa dimensão, logo, obtêm-se uma representação comprimida dos dados. O decodificador expande a representação comprimida para dados de alta dimensão, com o objetivo de reconstruir a entrada original [47].

A Figura 21 a seguir mostra uma representação resumida dos Autoencoders com seus principais componentes: o codificador que receberá os dados, a representação comprimida que extraí as informações mais importantes dos dados originais e o decodificador reconstrói os dados originais.

O Autoencoder tem a capacidade de reconstruir com eficácia os recursos originais, aprendendo uma nova representação através das camadas intermediárias (camadas ocultas). As camadas de um Autoencoder são formadas por neurônios ou nós [40]. Neste

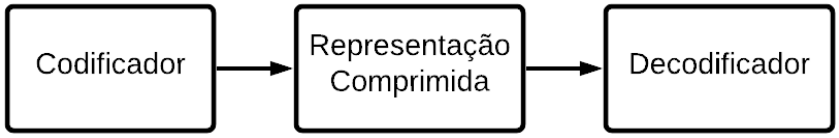

Figura 21: Representação Resumida do Autoencoder.

estudo é empregado um Autoencoder *Undercomplete*, onde as camadas de entrada e de saída possuem o mesmo número de neurônios, com uma menor quantidade de neurônios nas camadas ocultas.

O Codificador do Autoencoder pode ser representado com a função de extração de características que mapeia o conjunto de treinamento para uma representação latente:

$$h : \mathbb{R}^D \rightarrow \mathbb{R}^K. \tag{2.13}$$

Já o Decodificador tem como função a reconstrução da representação gerada por h retornando esta representação ao seu estado o espaço original:

$$g : \mathbb{R}^K \rightarrow \mathbb{R}^D \tag{2.14}$$

Dado um conjunto de dados $\mathbf{X}$, o Codificador terá a função $\mathbf{f}(\mathbf{x}) = h$, as camadas ocultas iguais a h e decodificador será a função $\mathbf{g}(\mathbf{h})$ igual a x'. O Autoencoder pode ser descrito como:

$$g(f(x)) = x'. \tag{2.15}$$

A saída x' será uma versão aproximada dos dados originais x após a sua compactação nas camadas ocultas do Autoencoder. A Figura 22 mostra o codificador vários neurônios e recebendo os dados de entrada, as camadas intermediárias com menos neurônios que a camada anterior e a saída representada pelo decodificador realizando a reconstrução dos dados originais.

Para a configuração do Autoencoder é necessário definir os seguintes parâmetros.

Construção do Autoencoder:

a) O modelo *Sequential* é aplicado para a construção do Autoencoder usado neste trabalho, sendo composto por pilhas de camadas.

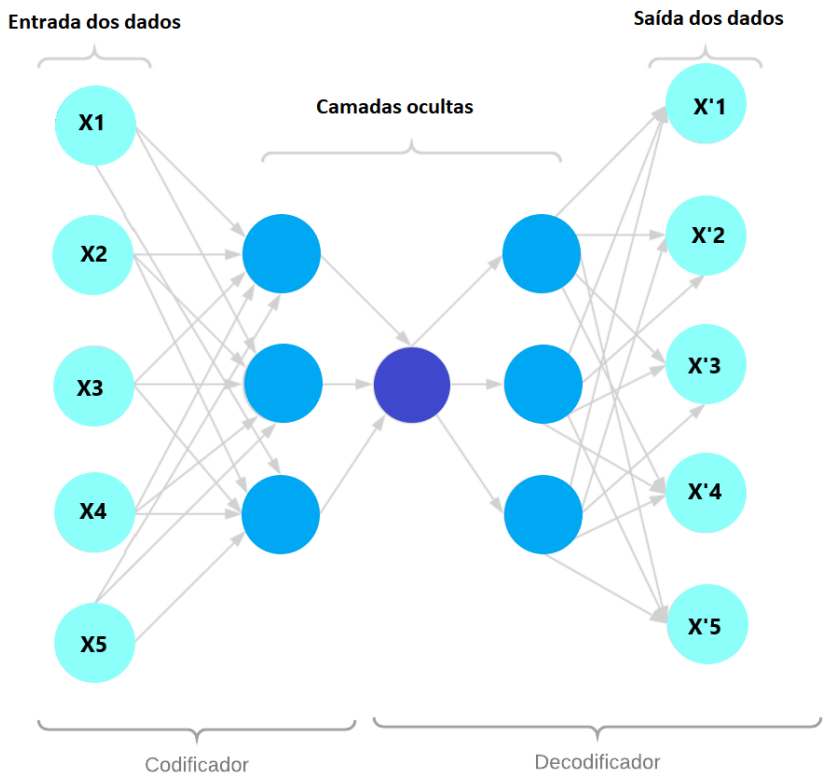

Figura 22: Representação do Autoencoder.

b) Cabe definir o número de camadas de intermediárias.

c) Função de Ativação - A função de ativação é definida a cada camada do Autoencoder. As funções de ativações não-lineares mais utilizadas são mostradas na Figura 23, a ReLU (Unidade Linear Retificadora - *Rectified Linear Unit*) e *Sigmoide* [47].

A função de ativação ReLU é a função de ativação mais comumente usada em modelos de aprendizado profundo. Esta função retorna 0 se receber qualquer entrada negativa, mas para qualquer valor positivo x ela retorna o mesmo valor. A função ReLU é

$$f(x) = \begin{cases} 0, \text{se } x \leq 0 \\ x, \text{se } x > 0 \end{cases} . \tag{2.16}$$

Por sua vez, a função de ativação Sigmoide pode ser definida como:

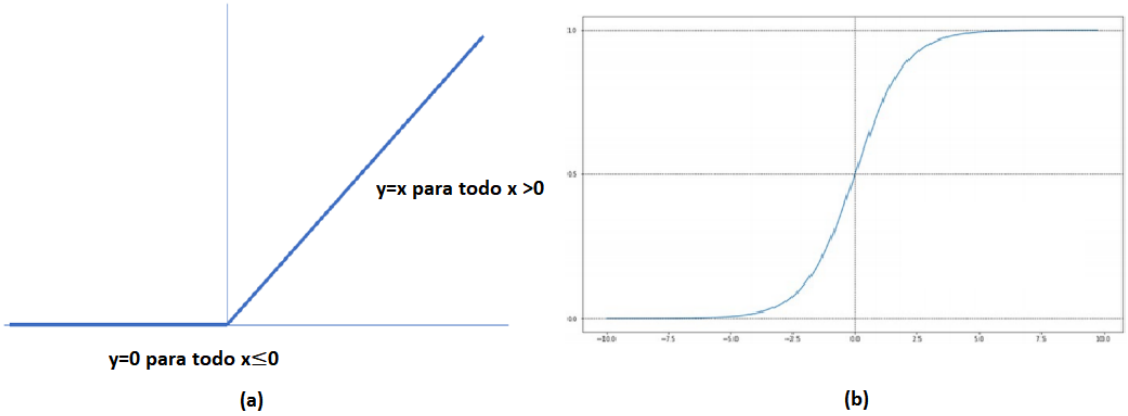

Figura 23: Representação das Funções ReLU (a) e (b) Sigmoide.

$$f(x) = \frac{1}{1 - e^{-x}} \tag{2.17}$$

para todo x real.

d) Função de perda - Avalia a diferença entre entrada de dados original e a saída dos dados reconstruída. A função de perda do treinamento de um Autoencoder está relacionada a diferença entre a entrada e a saída apresentada pela rede, definida como:

$$\text{Loss}(x, x') = \text{MSE}(x, x') \text{ ou } \text{MAE}(x, x'). \tag{2.18}$$

As funções mais utilizadas em Aprendizado de Máquina para esta perda são o MSE (*Mean Squared Error*) e o MAE (*Mean Absolute Error*).

- O MSE mede o erro quadrático médio entre os valores previstos (y_i^p) e os valores reais (y_i), sendo definido por:

$$\text{MSE} = \frac{1}{n}\sum_{i=1}^{n}(y_i - y_i^p)^2 \tag{2.19}$$

- O MAE é a soma das diferenças absolutas entre as variáveis alvo e previstas. Representa a média dos erros absolutos em um conjunto de previsões, sem considerar as suas direções, sendo dado por:

$$\text{MAE} = \frac{1}{n}\sum_{i=1}^{n}|y_i - y_i^p|. \tag{2.20}$$

e) Otimizador - É o algoritmo responsável por minimizar ou maximizar uma função. Geralmente, é aplicado para minimizar a função de perda. Os otimizadores aprendem e atualizam os parâmetros para que a função de perda seja minimizada conforme ocorre o treinamento do autoencoder [49]. O otimizador usado neste trabalho é o Adam, bastante popular em aplicações de aprendizado profundo em visão computacional e em processamento de linguagem natural.

- Perda - É semelhante à função de perda quando definimos o modelo do Autoencoder. Funções MAE ou MSE são aplicadas e a cada *batch*/lote é calculada a perda entre o valor previsto e valor verdadeiro. Para a detecção de anomalias, esta métrica permite separar os dados considerados normais dos com anomalias, que tendem a apresentar um maior erro de reconstrução [47].

Os hiperparâmetros de treinamento do Autoencoder são:

a) Épocas - Uma época é a passagem pelo Autoencoder de todo o conjunto de dados de treinamento do modelo.

b) *Batch Size* - É o número inteiro de amostras a serem executadas durante uma época.

c) *Early Stopping* - O treinamento é interrompido se não ocorrer melhora no treinamento e é salvo o melhor modelo atingido [50].

2.4 **Curva ROC e métricas de avaliação**

A Curva Característica de Operação do Receptor (Curva ROC - *Receiver Operating Characteristic Curve*) é uma técnica para visualizar, organizar e selecionar classificadores com base em seu desempenho [51] e descreve quantitativamente o desempenho de um teste [52]. Este gráfico será empregado para a escolha de limiares para a classificação das amostras processadas pelos detectores de risco de queda baseados em algoritmos de aprendizado de máquina kNN, PCA e Autoencoder. A curva ROC representa o compromisso entre as taxas de acerto e as taxas de falsos alarmes dos classificadores, úteis para a visualização e a análise do comportamento de sistemas de diagnóstico, para testes diagnósticos na área médica. Nos últimos anos se observou um aumento do uso desta curva na área de aprendizado de máquina [51].

A Curva ROC relaciona a Taxa de Verdadeiros Positivos (TPR - *True Positive Rate*) ou Sensibilidade com a Taxa de Falsos Positivos (FPR - *False Positive Rate*) ou "1 - Especificidade". Como a Curva ROC é uma ferramenta aplicada em testes diagnósticos, a Sensibilidade é a probabilidade de um resultado positivo dado que um indivíduo é portador de uma enfermidade, e a especificidade é a probabilidade do resultado negativo quando o indivíduo não possui enfermidade. As medidas de sensibilidade e especificidade são independentes entre si [52].

Em problemas de classificação, a curva ROC é utilizada para avaliar a distribuição das amostras entre duas classes. O classificador pode produzir duas saídas, que podem gerar quatro resultados conforme apresentados na matriz de confusão da Tabela 4.

Tabela 4: Matriz de Confusão.

Classe Prevista	**Classe Atual**	
	Positiva	**Negativa**
Positiva	Verdadeiro Positivo **TP**	Falso Positivo **FP**
Negativa	Falso Negativo **FN**	Verdadeiro Negativo **TN**
Total	**P = TP + FN**	**N = FP + TN**
Desempenho	Sensibilidade = TP/TP+FN	Especificidade = TN/FP+TN

A partir da matriz de confusão, obtêm-se métricas como:

a) TPR ou Sensibilidade - É o percentual de amostras da classe positiva previstas corretamente [53]

$$\text{TPR} = \text{Recall} = \text{Sensibilidade} = \frac{\text{TP}}{\text{TP} + \text{FN}} = 1 - \text{FNR}. \tag{2.21}$$

b) Especificidade ou TNR (Taxa de Verdadeiros Negativos - *True Negative Rate*) - É o percentual de amostras da classe negativa previstas corretamente [53]

$$\text{TNR} = \text{Especificidade} = \frac{\text{TN}}{\text{TN} + \text{FP}} = 1 - \text{FPR}. \tag{2.22}$$

c) FPR - É o percentual de amostras da classe negativa classificadas como positivos

$$\text{FPR} = 1 - \text{Especificidade} = \frac{\text{FP}}{\text{TN} + \text{FP}}. \tag{2.23}$$

d) FNR (Taxa de Falsos Negativos - *False Negative Rate*) - É o percentual de amostras positivas classificadas como negativos

$$\text{FNR} = \frac{\text{FN}}{\text{FN} + \text{TP}} = 1 - \text{TPR}. \tag{2.24}$$

e) Acurácia - É o percentual de amostras classificadas corretamente nas duas classes [53]

$$\text{Acurácia} = \frac{\text{TN} + \text{TP}}{\text{TN} + \text{TP} + \text{FN} + \text{FP}}. \tag{2.25}$$

f) Precisão - Mede a exatidão de um resultado positivo previsto [53]

$$\text{Precisão} = \frac{\text{TP}}{\text{TP} + \text{FP}}. \tag{2.26}$$

g) F1 - Média harmônica entre Precisão e Sensibilidade

$$F1 = 2 \times \frac{\text{Precisão} \times \text{Sensibilidade}}{\text{Precisão} + \text{Sensibilidade}} = \frac{\text{TP}}{\text{TP} + \frac{1}{2}(\text{FP} + \text{FN})}. \tag{2.27}$$

Através da TPR e FPR, é formada a curva ROC com a TPR ou Sensibilidade no eixo das ordenadas (y) e a FPR ou "1 - Especificidade" no eixo das abcissas (x).

Pontos importantes da curva ROC são aqueles correspondentes a TPR = 0 e FPR = 0 que representa nunca emitir uma classificação positiva e o com TPR = 1 e FPR = 1 quando o classificador obtém apenas classificações positivas. O classificador perfeito produz TPR = 1 para quaisquer valores de FPR [51], como apresentado na Figura 24.

Outro método para se avaliar um classificador é a Área Sob a Curva (AUC - *Area Under the Curve*), uma medida de desempenho de um teste que é estimada a partir de todas as sensibilidades e especificidades [52]. A AUC tem seu valor entre 0 e 1, quanto maior a área sob a curva ROC, maior será a AUC. Através de um gráfico é produzida uma linha diagonal entre os pontos (0, 0) e (100%, 100%) com área de 0,5, como mostra a Figura 24 [51]. O melhor desempenho de um classificador é obtido quando a área sob a

curva aproxima-se do ponto (0, 100%) e o pior desempenho no ponto (100%, 0).

Uma vantagem da curva ROC é a possibilidade de escolher o ponto de corte que otimiza o desempenho do modelo. Quando a AUC está próxima de 1, esta indica que maior será a probabilidade do modelo prever um verdadeiro positivo ou verdadeiro negativo.

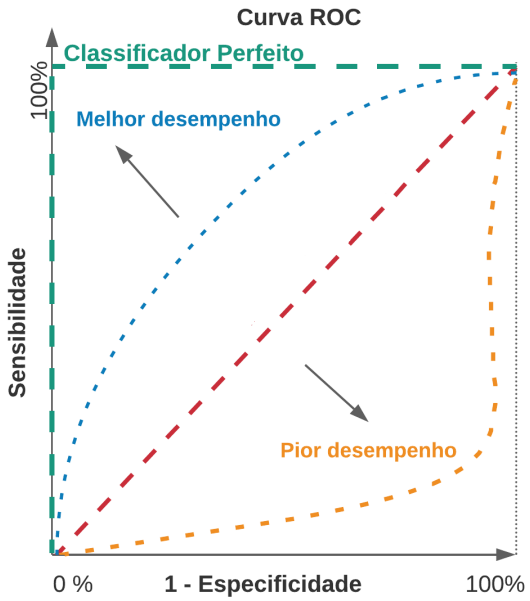

Figura 24: Desempenho do Classificador pela Curva ROC.

A Figura 25(a) ilustra uma situação ideal quando duas classes são separadas perfeitamente, com AUC de 100%, as densidades de probabilidade de TP = (verdadeiros positivos) e de TN = (verdadeiros negativos) não se sobrepõem. Na Figura 25(b) as classes se sobrepõem, os limiares podem aumentar ou reduzir a quantidade de amostras TN = e TP =, e neste exemplo, o modelo tem 75% (AUC) de chances de distinguir classes corretamente. Em Figura 25(c) as classes se sobrepõem totalmente, é considerado o pior caso, pois com a AUC de 50%, o modelo não é capaz de distinguir classes, e por fim, na Figura 25(d), com AUC igual a 0%, significa que o modelo está prevendo uma classe negativa como uma classe positiva e vice-versa.

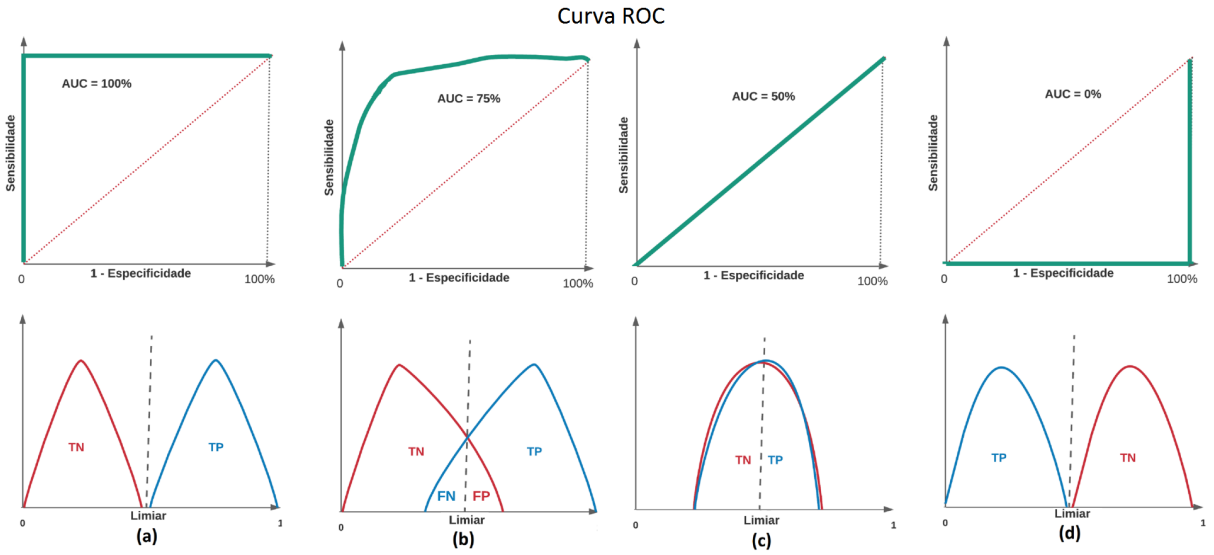

Figura 25: Desempenho do Classificador pela Curva ROC e AUC.

As amostras da CSI nos cenários "Sem risco de queda" e "Com risco de queda" são divididas em duas classes para aplicação na curva ROC.

O eixo de sensibilidade na curva ROC indica a capacidade do classificador de identificar corretamente as amostras da classe positiva, "Com risco de queda". Por outro lado, a especificidade é a capacidade do classificador de identificar corretamente amostras da classe negativa, "Sem risco de queda".

Em geral, busca-se o melhor compromisso entre a sensibilidade e a especificidade, ou seja, é definido o limiar que satisfaça um compromisso entre falsos positivos e negativos [54].

A partir da curva ROC, escolhe-se um Ponto de Corte que é um limiar associado a valor particular de Sensibilidade e 1 - Especificidade [52]. O número de pontos de corte é determinado segundo a necessidade do estudo [52].

Para este trabalho foram escolhidos como Pontos de Corte:

- Ponto de Corte 1 - É obtido através de um gráfico conhecido como TG-ROC (*Two-Graph Receiver Operating Characteristic*) que demonstra o desempenho de um teste e apresenta sensibilidade e a especificidade no eixo das ordenadas [52]. O ponto de corte é, em geral, adotado como o limiar de interseção entre as curvas no TG-ROC, ou seja, o limiar para o qual sensibilidade e especificidade são aproximadamente iguais. A Figura 26 ilustra que enquanto a Sensibilidade decresce, a especificidade aumenta [52].

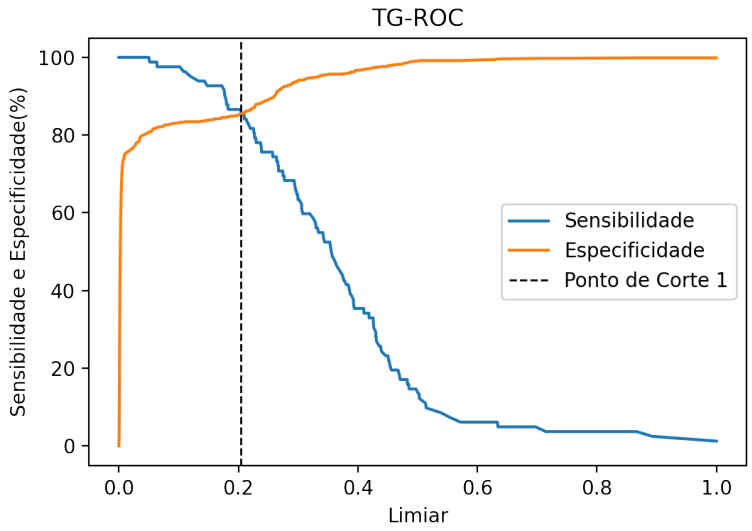

Figura 26: Ponto de Corte 1.

O ponto de corte é aquele onde as amostras das classes "Sem risco de queda" e "Com risco de queda" produzem a mesma proporção de acertos, e assim é dado por:

$$\text{Ponto de Corte 1} = \text{Sensibilidade} \approx \text{Especificidade} \tag{2.28}$$

- Ponto de Corte 2 - É o limiar de maior acurácia, ou seja, o limiar com maior taxa de acertos entre as amostras pertencentes às duas classes. Em testes com classes desbalanceadas não é a escolha mais adequada, pois a classe majoritária tem uma maior influência na acurácia. Como neste trabalho, as classes são balanceadas, ou seja, as amostras analisadas pelo detector de risco de queda têm a mesma quantidade de registros em cada classe, a escolha pelo limiar que apresenta maior acurácia não favorece a nenhuma classe. O ponto de corte 2 é dado por:

$$\text{Ponto de Corte 2} = \text{Máxima Acurácia} \tag{2.29}$$

Caso a amostra da CSI produza uma saída inferior ao ponto de corte, considera-se que a mesma pertence à classe "Sem risco de queda". Por outro lado, se ela está acima do ponto de corte, considera-se que pertence à classe "Com risco de queda" como mostra a Figura 27.

As classes "Sem risco de queda" e "Com risco de queda" classificadas a partir do

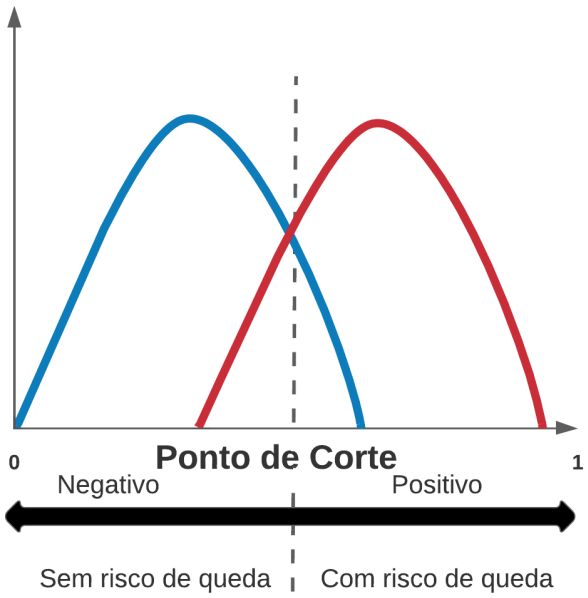

Figura 27: Classificação da amostra da CSI a partir do Ponto de Corte.

ponto de corte são distribuídas conforme a Tabela 5.

Tabela 5: Matriz de Confusão das amostras CSI.

Classe Prevista	**Classe Atual**	
	Com risco de queda	**Sem risco de queda**
Com risco de queda	**TP**	**FP**
Sem risco de queda	**FN**	**TN**

O cenário ideal é que no ponto de corte as amostras “Sem risco de queda” e “Com risco de queda” sejam avaliadas corretamente, mas encontrar um limiar para que não encontre falsos positivos ou negativos é extremamente difícil [54].

Como alternativa, pode-se usar mais de um limiar que torna os classificadores mais conservadores ou liberais, permitindo-se mais falsos positivos ou negativos, ou seja, amostras de uma classe previstas incorretamente. A Figura 28 mostra que um limiar tido como conservador tem menor sensibilidade e maior especificidade, ou seja, menos amostras verdadeiras são identificadas e consequentemente menos de falsos positivos. Um limiar liberal, terá maior sensibilidade e menor especificidade, mais amostras positivas são detectadas, mas muitos erros podem ser cometidos, pois, aumentará o número de verdadeiros positivos e, portanto, aumenta o número de falsos positivos.

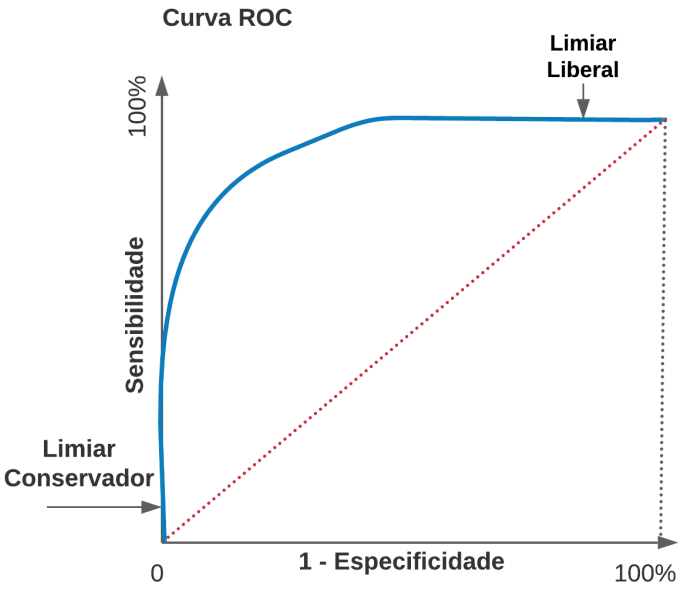

Figura 28: Desempenho do Classificador de acordo com Limiar.

2.5 Normalização dos dados

É uma técnica recomendável para os dados em aprendizado de máquina, pois os atributos podem ter valores distintos, portanto visa a evitar que um atributo domine os demais [55].

A normalização por amplitude pode ser por reescala ou por padronização. A normalização por reescala ou *min-max* define valores máximo e mínimo para todos os valores dos atributos sendo dada por

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \tag{2.30}$$

onde x' é o valor da variável após a normalização *min-max*, x é o valor atual, $x_{\min}$ o valor mínimo e $x_{\min}$ o valor máximo.

A normalização por padronização ocorre a cada valor de atributo a ser normalizado e desse modo cada atributo pode apresentar limites inferiores e superiores distintos, mas terão os mesmos valores para as medidas de escala e espalhamento. Se as medidas de localização e de escala forem a média (μ) e a variância (σ), respectivamente, os valores de um atributo são convertidos para um novo conjunto de valores com média 0 e variância

unitária, via [55]

$$x' = \frac{x - \mu}{\sigma} \tag{2.31}$$

Geralmente, é preferível padronizar a reescalar, pois, a padronização enfatiza valores anômalos ou *outliers*. É possível durante a operação de normalização fazer com que os atributos mais importantes possuam limites maiores [55].

2.6 Validação dos dados

Neste trabalho são aplicadas duas técnicas para a divisão das amostras entre os conjuntos de treinamento e de teste que permitem avaliar o desempenho do modelo, como ilustra a Figura 29 [56, 57].

- *Validação Hold-out* - Os dados são divididos aleatoriamente com 80% (por exemplo) dos dados destinados ao conjunto de treino e os 20% restantes para testes. A desvantagem desta técnica consiste em que não avaliamos os efeitos de todo o conjunto de dados no treinamento e no teste não permitindo avaliar a variabilidade do modelo com os dados, consequentemente não sabemos se o desempenho do modelo pode variar com novos dados e até mesmo não fornecer bons resultados.

- *Validação cruzada k-Fold* - O conjunto de dados é dividido em blocos, e realizam-se treinamentos e testes com diferentes divisões do conjunto de dados. Neste trabalho, os dados foram divididos em $k = 5$ blocos. O conjunto de dados é dividido em cinco partes, quatro blocos equivalentes a 80% dos dados são usados para treinar o modelo e um bloco com os outros 20% das amostras é usado para teste. O procedimento é repetido 5 vezes, isto é, com os cinco blocos do conjunto de dados aplicados para teste. Esta técnica permite resultados mais robustos, pois apresenta uma melhor cobertura para o conjunto de dados durante os processos de treinamento e teste.

2.7 Detecção de Risco de Queda

Para detecção do risco de queda, são coletados amostras de CSI como descrito na seção 2.2.3, em que são simulados dois cenários: “Sem risco de queda” e “Com risco de queda”.

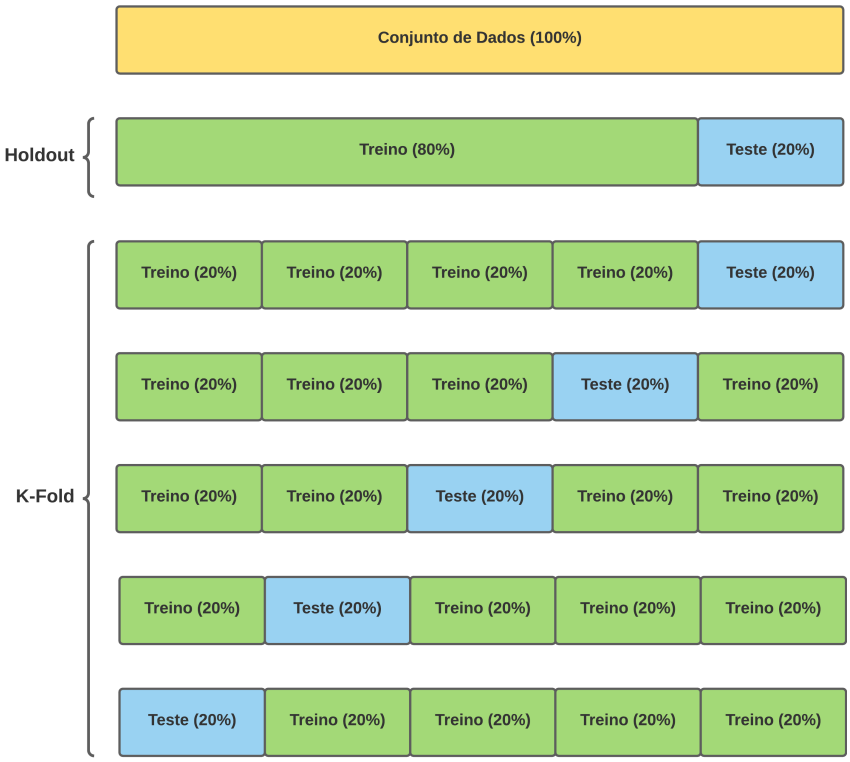

Figura 29: Tipos de validação dos dados.

As amostras de CSI são coletadas em um ambiente de testes com dois módulos ESP32, um para troca de informações com dispositivos na rede sem fio e outro módulo para captura da CSI. O módulo ESP32 para coleta da CSI está posicionado a 1 metro de distância da cama onde o voluntário estava deitado. Para cada amostra de CSI, obtêm-se os módulo das subportadoras, compreendendo as subportadoras L-LTF e HT-LTF de índices -32 a 31, para aplicação aos algoritmos de aprendizado de máquina.

Os detectores de risco de queda baseados nos três algoritmos de Aprendizado de Máquina são treinados para aprender apenas a situação “Sem risco de queda”, que reflete a situação normal do ambiente da enfermaria. Este é um cenário que pode ser aprendido rapidamente, sem expor ninguém a riscos, ao dispor no ambiente de teste os dispositivos de transmissão e coleta. Além disso, parece ser inviável obter todos os padrões possíveis de CSI correspondentes a situações de risco de queda. Assim, aborda-se o problema, treinando-se o sistema somente com amostras “Sem risco de queda”, de forma que circunstâncias diferentes das aprendidas sejam consideradas como situações anormais. A associação do risco de queda à detecção de anomalias no ambiente de propagação permite generalizar e detectar situações de risco de queda possivelmente não vislumbradas, já que

as pessoas são fisicamente muito diferentes e movimentam-se diferentemente.

Consequentemente, as situações simuladas no ambiente de teste são separadas em duas classes:

a) Sem risco de queda - O voluntário permanece deitado na cama colocada no ambiente de testes (um quarto). São capturadas 3000 amostras de CSI desta classe, coletadas em diferentes dias e aplica-se a validação *hold-out* ou validação cruzada *k-Fold* para a divisão das amostras para treino (80% – 2400 registros) e teste (20% – 600 registros) do detector de risco de quedas.

b) Com risco de queda - o voluntário levanta da cama, caminha, corre, ou simula uma queda, movimentos que diferem da situação "Sem risco de queda". As amostras coletadas desta classe para análise pelo sistema de detecção de quedas são divididas em quatro grupos com 600 registros cada:

   (a) **Grupo 1** - O voluntário caminha pelo ambiente de testes durante a captura das amostras da CSI.

   (b) **Grupo 2** - Durante a captura das amostras da CSI, o voluntário levanta da cama e permanece em pé próximo da cama.

   (c) **Grupo 3** - O voluntário levanta da cama, simula uma queda e permanece deitado no chão até o final da coleta da CSI.

   (d) **Grupo 4** - O voluntário está sentado em uma cadeira, a 1 metro de distância da cama do ambiente de testes.

Para a avaliação dos detectores de risco de queda são aplicadas para obtenção da Curva ROC as saídas dos classificadores para 600 amostras de teste da classe "Sem risco de queda" e outras 600 da classe "Com risco de queda". Assim, o conjunto empregado para obter a Curva ROC é balanceado. Cada detector de risco de queda é analisado por meio da sensibilidade e especificidade de identificação dos registros de CSI de cada classe.

Os detectores de risco de queda foram avaliados a partir de duas metodologias de testes:

- **1^a - Avaliação das amostras de "Com risco de queda" com diferentes situações de risco.**

Os detectores de risco de queda são avaliados usando 600 amostras "Com risco de queda" (com 150 amostras de cada grupo) e amostras de teste da classe "Sem risco de queda". O objetivo desta configuração é analisar se os detectores de risco de queda tem capacidade de identificar os registros "Com risco de queda", sem especificar a situação de risco produzida durante a captura das amostras. Nesta metodologia os desempenhos dos classificadores são avaliados pela validação *Hold-out* e *k-Fold*, são observadas as diferenças dos resultados obtidos treinamento e teste dos modelos.

- **2^a - Avaliação das amostras "Com risco de queda" por grupos.**

  Os detectores de risco de queda são avaliados usando 600 amostras "Com risco de queda" de cada grupo e 600 registros da classe "Sem risco de queda". Os detectores de risco de queda são avaliados para cada grupo, separadamente, com situações específicas de risco de queda, sendo analisado se as amostras são classificadas corretamente. Nesta metodologia, os desempenhos dos classificadores são avaliados pela validação *Hold-out*.

As duas metodologias foram avaliadas nos pontos de corte listados na Seção 2.4 e analisadas as diferenças produzidas na escolha do ponto de corte do classificador.

2.8 Implementação dos Classificadores para a Detecção de Risco de Queda

A implementação dos algoritmos de Aprendizado de Máquina foi realizada através da linguagem de programação Python, que é uma linguagem de programação de alto nível orientada a objetos, de código aberto, com uso em diversas aplicações, e com licença compatível com a GPL (*General Public License*) – sujeita a menos restrições, o que possibilita sua incorporação em produtos proprietários [58]. Através de bibliotecas padrão do Python ou de terceiros é possível implementar diversas funções. Nos algoritmos de Aprendizado de Máquina empregados neste trabalho são utilizadas as seguintes bibliotecas:

- *Numpy* - É o pacote fundamental para a computação científica em Python. É uma biblioteca que fornece um objeto de matriz multidimensional, rotinas para operações rápidas em matrizes, incluindo matemática, lógica, manipulação de forma, classificação, seleção, entrada/saída, Transformadas Discretas de Fourier, álgebra linear básica, operações estatísticas básicas e simulação aleatória [59].

- *Pandas* - É uma biblioteca de código aberto que fornece estruturas de dados de alto desempenho, que permite o uso de ferramentas de análise de dados [60].

- *Scikit-learn* - Permite a implementação de algoritmos de aprendizado de máquina para problemas supervisionados e não supervisionados. Este pacote facilita a produção de soluções de Aprendizado de Máquina para não-especialistas usando uma linguagem de alto nível de uso geral [61].

- *Matplotlib* - Biblioteca que permite a criação de gráficos 2D, usado para o desenvolvimento de aplicativos, scripts interativos e a geração de imagens com qualidade de publicação em *interfaces* de usuário e sistemas operacionais [62].

- *Seaborn* - Biblioteca de visualização de dados baseada em *Matplotlib* e fornece uma interface de alto nível para se desenhar gráficos estatísticos atraentes e informativos [63].

- *TensorFlow* - É uma plataforma completa de código aberto para *Machine Learning*, que possui um ecossistema abrangente e flexível de ferramentas, bibliotecas e recursos da comunidade, de forma a permitir aos pesquisadores levar adiante aplicações de ML de última geração e aos desenvolvedores criar e implantar aplicativos com tecnologia de ML [64].

- *Keras* - Biblioteca que fornece uma interface para redes neurais. O Keras é uma API de aprendizado profundo, executada na plataforma de aprendizado de máquina TensorFlow. Foi desenvolvido com foco em possibilitar experimentação rápida [65].

O Capítulo 3 descreve como os algoritmos são utilizados para detecção do risco de queda, sua atuação como classificadores das amostras de CSI entre as classes “Sem risco de queda” ou “Com risco de queda”, trazendo resultados e análises para os classificadores baseados em kNN, PCA e Autoencoder, respectivamente.

3 RESULTADOS: DESEMPENHOS DOS CLASSIFICADORES

Este capítulo apresenta as implementações dos algoritmos de Aprendizado de Máquina kNN, PCA e Autoencoder, seus usos como classificadores nos detectores de risco de queda, os testes aplicados e a melhor configuração para cada algoritmo.

O objetivo principal deste trabalho é avaliar o desempenho dos classificadores para identificação de anomalias no ambiente de teste, sem especificar a situação que ocasionou os registros de risco de queda. O propósito é detectar se houve uma anomalia no ambiente e não identificar qual situação gerou anomalia nas amostras de CSI. Assim, neste capítulo são apresentados os resultados e análises da metodologia de testes - **Avaliação das amostras de "Com risco de queda" de diferentes situações** descrita na Seção 2.7.

Os detectores de risco de queda são treinados usando apenas amostras de CSI pertencentes à classe "Sem risco de queda". As amostras são separadas entre os conjuntos de treinamento e teste por dois métodos de validação: *Hold-out* e na cruzada *k-Fold*.

Na validação *Hold-out*, 80% das amostras na classe "Sem risco de queda" são aplicadas para treinamento (2400 registros) e 20% das amostras (600 registros) desta classe são aplicadas para testes dos classificadores.

Na validação cruzada *k-Fold*, as amostras da classe "Sem risco de queda" são divididas aleatoriamente entre 5 blocos. São usados 4 blocos para o treinamento do classificador, num total de 2400 amostras, e o teste emprega o bloco restante, com 600 amostras. O processo de treinamento e teste é aplicado 5 vezes alternando o bloco usado como conjunto de teste.

Para cada método de validação são realizados os testes dos classificadores através das 600 amostras de teste da classe "Sem risco de queda" e 600 amostras da classe "Com risco de queda".

Obtêm-se as curvas ROC para os classificadores e apresenta-se neste capítulo os resultados dos modelos com melhor desempenho (maior AUC). Foram escolhidos dois pontos de corte, em função do desempenho observado na curva ROC, para previsão das amostras entre as classes "Sem risco de queda" e "Com risco de queda". Os pontos de corte escolhidos são especificados na Seção 2.4, o ponto de corte 1 responde quando a sensibilidade e especificidade são aproximadamente iguais e o ponto de corte 2 quando se obtém a maior acurácia.

A metodologia de testes - **Avaliação das amostras "Com risco de queda" por grupos** permite avaliar o desempenho dos classificadores para diferentes situações de risco de queda separadamente. Os resultados e análises dessa metologia estão disponíveis nos Apêndices B.1, B.2 e B.3.

3.1 Classificador Baseado em kNN

Para a detecção de anomalias, o algoritmo kNN é treinado para obter a distância aos k vizinhos próximos sem a atribuição de classes (modo não supervisionado). Dado k, treina-se o algoritmo, após treinamento, obtêm-se as distâncias aos vizinhos mais próximos, e calcula-se a média das distâncias. As amostras avaliadas como normais são as mais próximas aos padrões aprendidos, as k padrões armazenados, enquanto as amostras consideradas anômalas estão mais distantes dos padrões aprendidos. Estratégia similar para detecção de anomalias pode ser vista em [66]. Define-se uma medida de distância entre padrões e estabelece-se o número de exemplos k. O valor de k pode ser ajustado visando melhorar o desempenho do algoritmo.

3.1.1 Diagrama de Blocos do kNN

A Figura 30 mostra diagrama de blocos do classificador baseado no kNN para a detecção de quedas a partir da CSI.

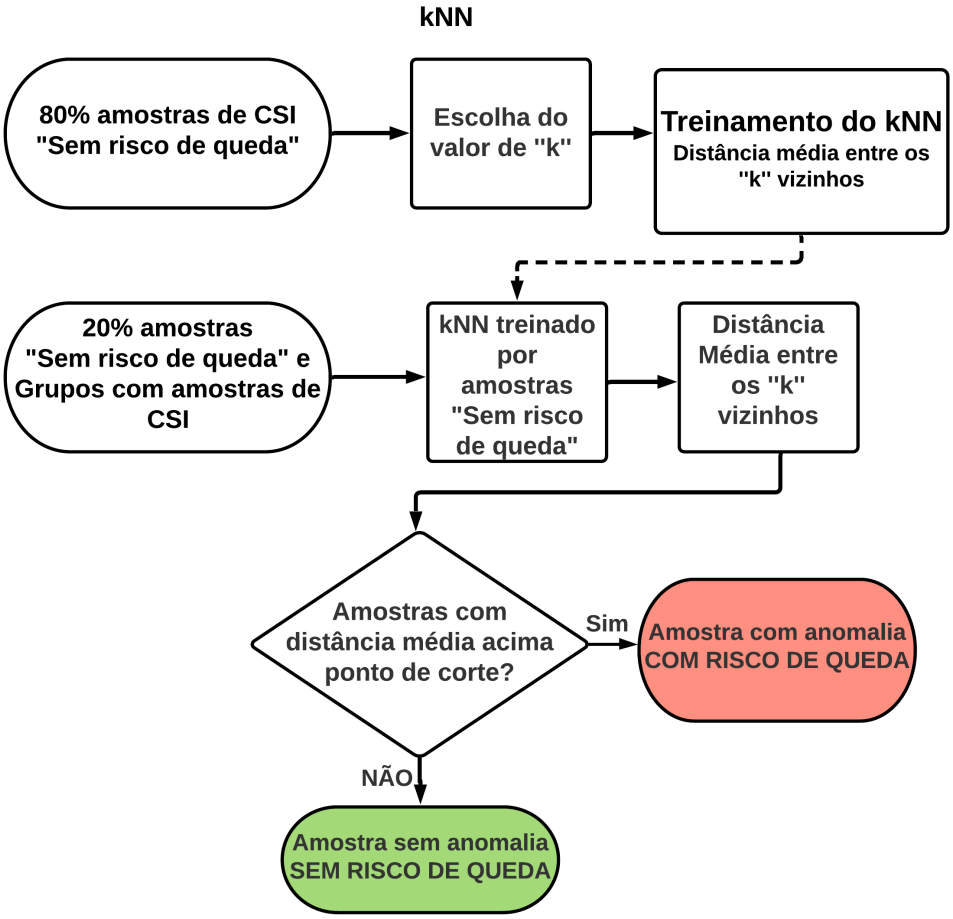

Figura 30: Representação do Classificador baseado em kNN.

3.1.2 Pseudocódigo do Classificador kNN

Os pseudo-códigos para o treinamento e o teste do classificador baseado na técnica kNN são apresentados nos Algoritmos 1 e 2.

Algoritmo 1: kNN Treinamento

Dados: 80 % das amostras **"Sem risco de queda"** (2400 registros);
Resultado: Treinar o Classificador kNN;
1: Normalizar as amostras de CSI por padronização;
2: Treinar o kNN para o valor escolhido de k;

Algoritmo 2: kNN Teste

Dados: 20 % das amostras **"Sem risco de queda"** (600 registros);
Dados: Amostras **"Com risco de queda"** (600 registros);
Resultado: Detectar amostras de CSI com anomalias e risco de queda;
1: Normalizar as amostras por padronização;
2: Encontrar a distância média entre os k vizinhos das amostras de entrada no classificador;
3: Identificar as amostras com anomalias e risco de queda;

3.1.3 Descrição dos Testes do Classificador kNN

A Figura 30 apresenta o diagrama correspondente à aplicação do kNN no sistema de detecção de quedas a partir da CSI. O kNN aprende somente amostras de "Sem risco de queda" e para as amostras CSI na entrada a serem classificadas, computam-se as distâncias aos k vizinhos já aprendidos (somente amostras "Sem risco de queda") e empregamos a distância Euclidiana. Calcula-se a distância média correspondente.

Se a distância média está abaixo do limiar escolhido (ou ponto de corte), a entrada é classificada como "Sem risco de queda". Caso contrário, a entrada é classificada como "Com risco de queda", isto é, para amostras da classe "Com risco de queda", espera-se que a distância média seja maior já que representam anomalias relativamente à classe aprendida pelo algoritmo, que é a classe "Sem risco de queda".

O kNN é treinado para k igual a 3, 5, 7 e 9. Para treinamento do classificador kNN é escolhido o k que apresentar melhor desempenho (maior AUC).

3.1.4 Resultados

Nesta subseção são apresentados os resultados do classificador baseado no kNN. O classificador baseado no kNN é treinado para k igual a 3, pois verifica-se o melhor desempenho visto que apresenta maior AUC quando comparado aos outros valores de k, como mostra a Figura 31. Em seguida são aplicados os dois pontos de cortes para analisar o funcionamento do classificador e o comportamento para os diferentes limiares.

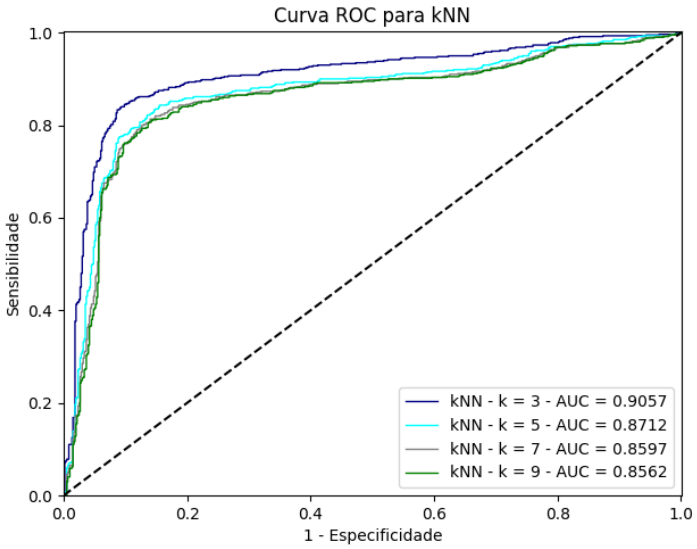

Figura 31: Curva ROC do kNN para diferentes valores de k - validação *Hold-out*.

3.1.4.1 Validação *Hold-out*

A Figura 32 apresenta as curvas de sensibilidade, especificidade e acurácia. Observa-se que os os dois pontos de corte são próximos com acurácias acima de 85%, indicando que para o conjunto de dados a maior parte das amostras é corretamente prevista.

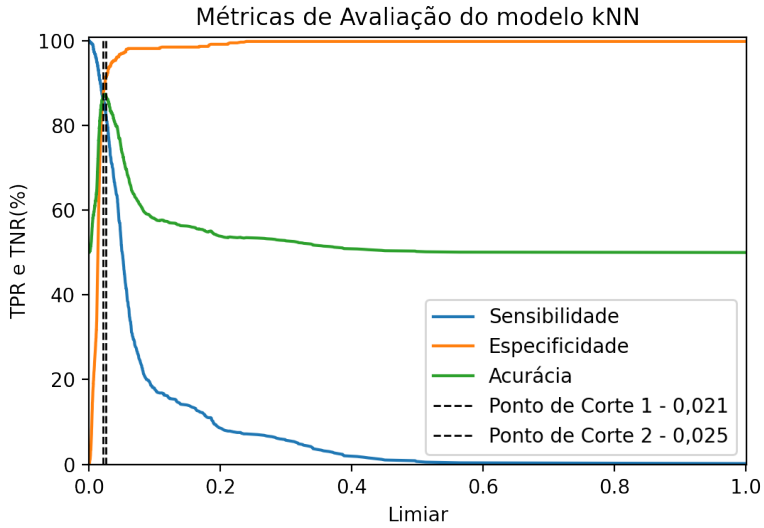

Figura 32: Localização dos pontos de corte para o classificador baseado em kNN para k = 3 - validação *Hold-out*.

A Figura 33 mostra os pontos de corte aplicados na Curva ROC para k igual a 3. Vê-se que o ponto 2 é mais conservador do que o ponto 1: o ponto de corte 1 acarreta

maior sensibilidade e menor especificidade que o ponto de corte 2. Assim, usando o ponto de corte 1, mais amostras de risco de queda são identificadas, porém, também produz-se mais falsos positivos, isto é, mais amostras da classe "Sem risco de queda" que são incorretamente classificadas como "Com risco de queda".

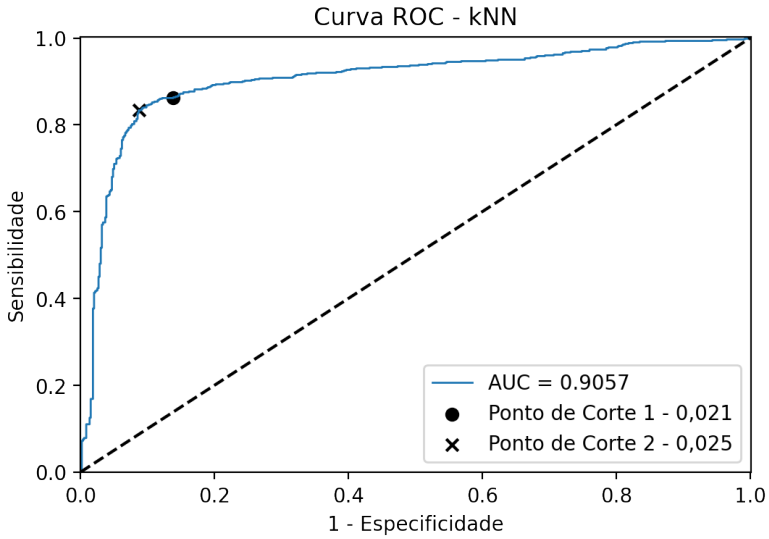

Figura 33: Localização dos pontos de corte na Curva ROC para o classificador baseado em kNN para $k = 3$ - validação *Hold-out*.

A Figura 34 apresenta as matrizes de confusão usando os dois pontos de corte. A Figura 34(a) apresenta a matriz de confusão para o classificador kNN usando o ponto de corte 1 e a maior parte das amostras são previstas corretamente, com acurácia, sensibilidade e especificidade de 86,17%, com 517 amostras previstas corretamente e 83 com erros. A Figura 34(b) apresenta a matriz de confusão para o classificador kNN usando o ponto de corte 2. Neste caso, temos maior acurácia de 87,33%, contudo este ponto de corte é conservador quando comparado ao anterior, pois menos amostras da classe "Com risco de queda" são previstas corretamente e, consequentemente, temos menos falsos positivos. Este ponto de corte atinge sensibilidade de 83,33% e especificidade de 91,33%, acertando mais a classe "Sem risco de queda" do que a classe "Com risco de queda". Em relação às amostras classificadas como "Com risco de queda" no ponto de corte 2, por ser mais conservador, temos 500 registros verdadeiros positivos e 52 registros falsos positivos. A quantidade de falsos positivos é menor que a obtida usando o ponto de corte 1, por ser mais conservador.

A Figura 34(c) mostra a quantidade de amostras previstas como a classe "Com

risco de queda" usando os dois pontos de corte. As barras na cor azul representam os acertos (verdadeiros positivos) e em vermelho os erros (falsos positivos).

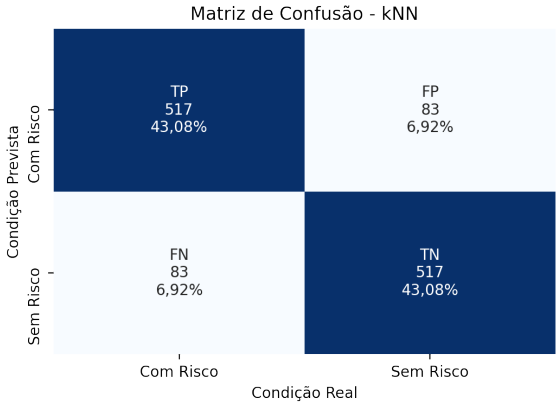

Ponto de Corte 1 = 0,021; Acurácia = 86,17%;

TPR = 86,17%; TNR = 86,17%; FPR = 13,83%; FNR = 13,83%

(a) Ponto de Corte 1.

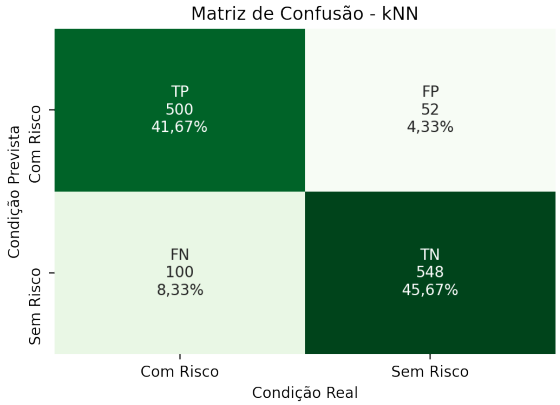

Ponto de Corte 2 = 0,025; Acurácia = 87,33%;

TPR = 83,33%; TNR = 91,33%; FPR = 8,67%; FNR = 16,67%

(b) Ponto de Corte 2.

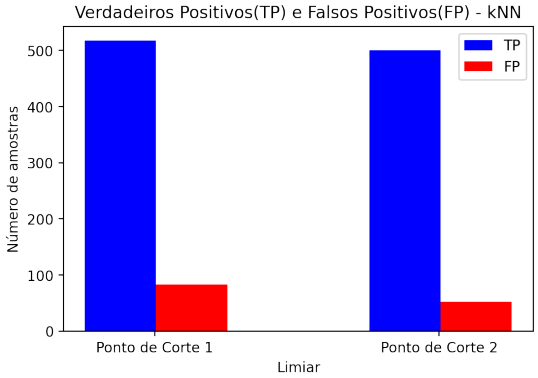

(c) Amostras previstas na classe "Com risco de queda".

Figura 34: Matriz de Confusão e Amostras TP e FP para os pontos de corte no classificador baseado em kNN para $k = 3$ - validação *Hold-out*.

Apesar do ponto de corte 2 apresentar um percentual menor de acertos e erros, ao comparar os resultados para os dois pontos de corte, vemos que as diferenças nos número de acertos é 17 e no de erros é 31. Dependendo da aplicação, prejuízos podem ser causados caso amostras de risco não sejam detectadas, então pode-se optar por um limiar mais liberal com maior sensibilidade. Em algumas circunstâncias, a escolha por um limiar mais conservador (um ponto de corte com especificidade maior que sensibilidade) menos amostras verdadeiros positivas são detectadas como amostras de CSI com anomalias ou de risco, no lugar de um sistema que produza menos falsos positivos.

3.1.4.2 Validação cruzada *k-Fold*

A Tabela 6 apresenta os resultados dos testes com as amostras da classe "Com risco de queda" e com os registros de testes da classe "Sem risco de queda" nos ponto de corte 1 e a Tabela 7 no ponto de corte 2.

Tabela 6: Resultados dos testes na validação cruzada *k-Fold* para Classificador baseado em kNN para $k = 3$ no ponto de corte 1.

Teste	**Ponto de Corte 1**					
Partição	**Ponto de Corte**	**TPR**	**TNR**	**FPR**	**FNR**	**Acurácia**
1	0,021	86,17%	86,17%	13,83%	13,83%	86,17%
2	0,053	57,50%	57,50%	42,50%	42,50%	57,50%
3	0,021	91,50%	91,50%	8,50%	8,50%	91,50%
4	0,036	64,50%	64,50%	35,50%	35,50%	64,50%
5	0,038	76,83%	76,83%	23,17%	23,17%	76,83%
Acurácia média	**75,30%**					

Tabela 7: Resultados dos testes na validação cruzada *k-Fold* para Classificador baseado em kNN para $k = 3$ no ponto de corte 2.

Teste	**Ponto de Corte 2**					
Partição	**Ponto de Corte**	**TPR**	**TNR**	**FPR**	**FNR**	**Acurácia**
1	0,025	83,33%	91,33%	8,67%	16,67%	87,33%
2	0,066	42,50%	80,17%	19,83%	57,50%	61,33%
3	0,022	90,83%	92,67%	7,33%	9,17%	91,75%
4	0,041	57,00%	77,50%	22,50%	43,00%	67,25%
5	0,044	71,17%	85,33%	14,67%	28,83%	78,25%
Acurácia média	**77,18%**					

Nesta subseção são apresentados os resultados da validação cruzada *k-Fold* na segunda e terceira partições, quando obteve-se a menor e a maior acurácia, respectivamente. Observa-se nas Tabelas 7 e 8, que de acordo com a partição, diferentes amostras CSI são aplicadas ao treinamento e teste do classificador e serão produzidos diferentes resultados. A acurácia média obtida na validação cruzada *k-Fold* é de 75,30% no ponto de corte 1 e de 77,18% no ponto de corte 2.

A Figura 35 mostra as curvas de sensibilidade, especificidade e acurácia e a Figura 36 mostra a localização dos dois pontos de corte na Curva ROC para k igual a 3, na 2^a partição quando obteve-se menor acurácia.

Observa-se que na segunda partição os pontos de corte são próximos, com acurácia máxima de 61,33%.

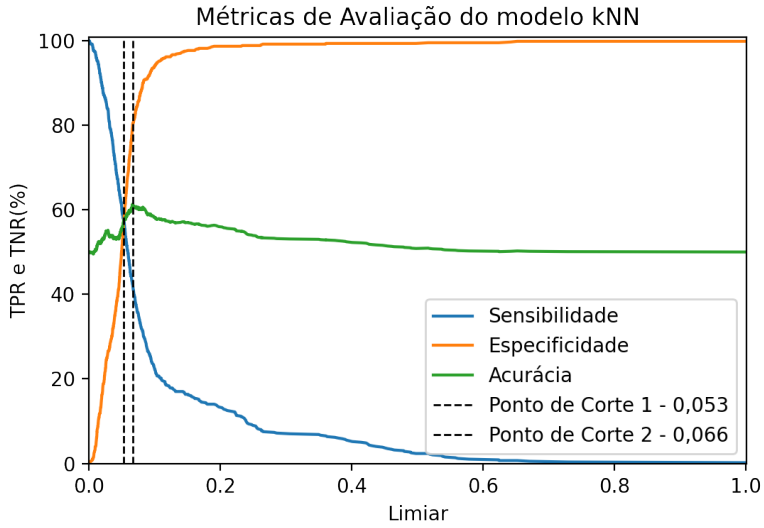

Figura 35: Localização dos pontos de corte no classificador baseado em kNN para $k = 3$ - validação cruzada *k-Fold* - 2^a partição.

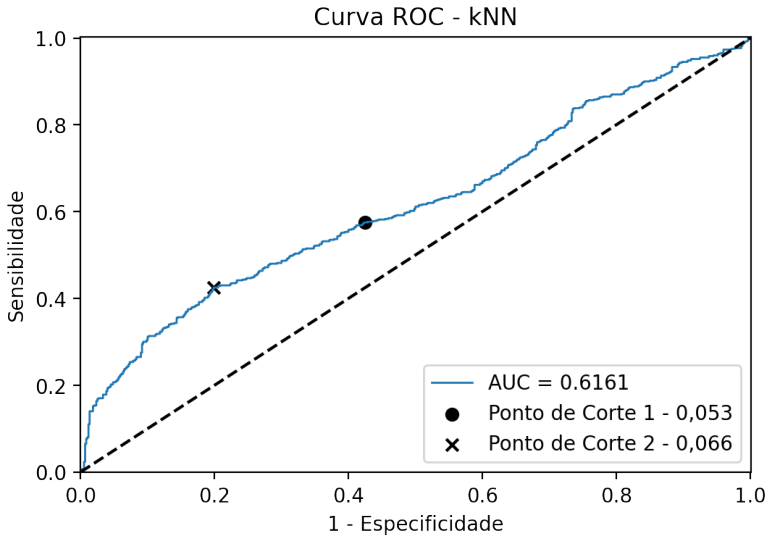

Figura 36: Localização dos pontos de corte na Curva ROC no classificador baseado em kNN para $k = 3$ - validação cruzada *k-Fold* - 2^a partição.

A Figura 37 apresenta as matrizes de confusão para os dois pontos de corte. A Figura 37(a) apresenta a matriz de confusão para o ponto de corte 1, com sensibilidade e especificidade de 57,50%, possuindo 345 amostras previstas corretamente e 255 com erros em cada classe.

A Figura 37(b) apresenta a matriz de confusão para o classificador no ponto de corte 2, com acurácia maior do que o ponto de corte 1. Neste ponto de corte temos uma acurácia de 61,33%, porém este limiar é conservador quando comparado ao ponto de corte anterior, pois um número menor de amostras da classe "Com risco de queda" são previstas corretamente e, consequentemente, tem-se menos falsos positivos. O ponto de corte 2 tem sensibilidade de 42,50% e especificidade de 80,17%. Sobre as amostras da classe "Com risco de queda" no ponto de corte 2, por ser mais conservador, apresenta 255 registros verdadeiros positivos e 119 falsos positivos. A comparação entre as amostras previstas como "Com risco de queda" nos dois pontos de corte são ilustradas na Figura 37(c).

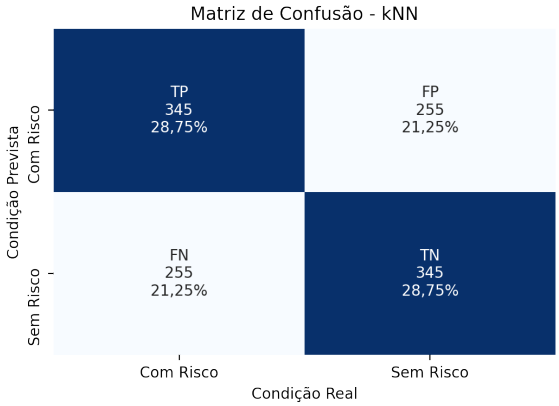

Ponto de Corte 1 = 0,053; Acurácia = 57,50%;

TPR = 57,50%; TNR = 57,50%; FPR = 42,50%; FNR = 42,50%

(a) Ponto de Corte 1.

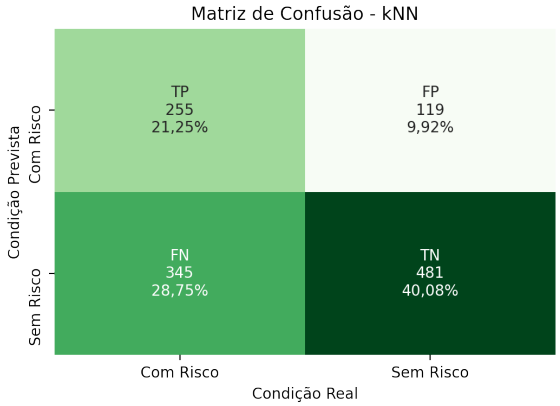

Ponto de Corte 2 = 0,066; Acurácia = 61,33%;

TPR = 42,50%; TNR = 80,17%; FPR = 19,83%; FNR = 57,50%

(b) Ponto de Corte 2.

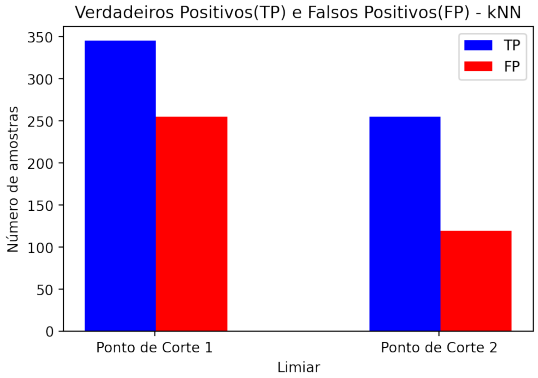

(c) Amostras previstas na classe "Com risco de queda".

Figura 37: Matriz de Confusão e Amostras TP e FP para os pontos de corte no classificador baseado em kNN para $k = 3$ - validação cruzada *k-Fold* - 2^a partição.

A Figura 38 mostra as curvas de sensibilidade, especificidade e acurácia e a Figura 39 mostra a localização dos dois pontos de corte na Curva ROC para k igual a 3, na terceira partição quando obteve-se maior acurácia.

Observa-se que na terceira partição os pontos de corte são próximos, com acurácia acima de 90%.

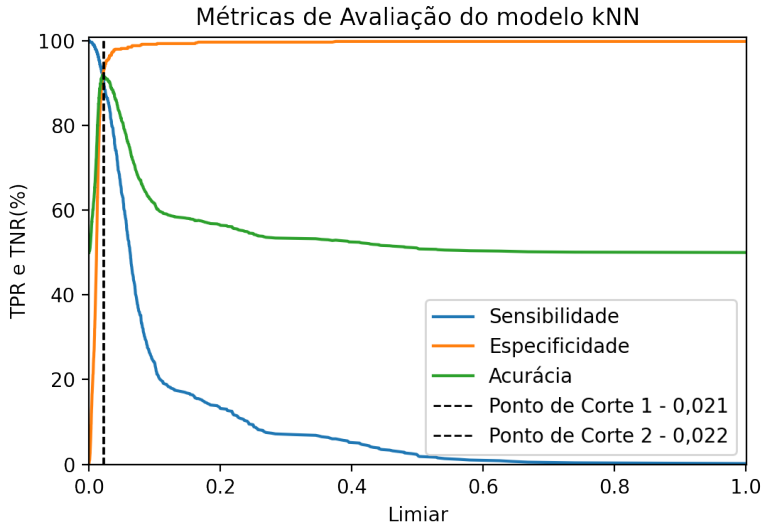

Figura 38: Localização dos pontos de corte no classificador baseado em kNN para $k = 3$ - validação cruzada *k-Fold* - 3^a partição.

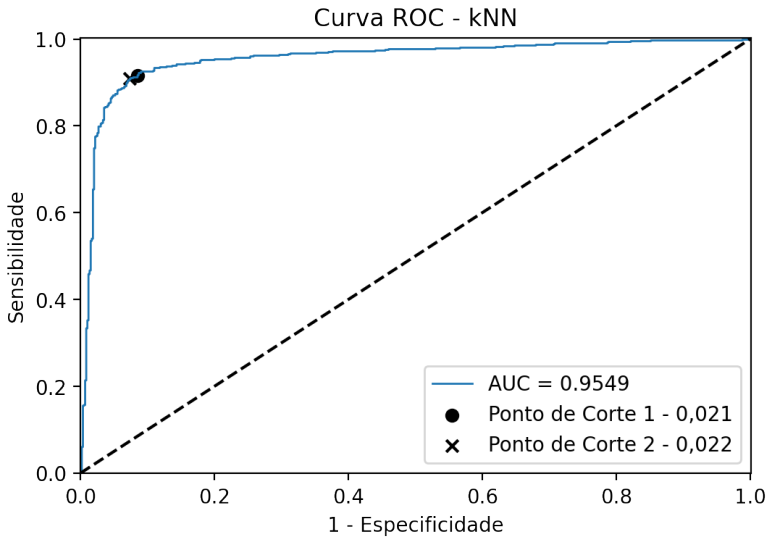

Figura 39: Localização dos pontos de corte na Curva ROC no classificador baseado em kNN para $k = 3$ - validação cruzada *k-Fold* - 3^a partição.

A Figura 40 apresenta as matrizes de confusão para os dois pontos de corte. A Figura 40(a) apresenta a matriz de confusão para o ponto de corte 1, com a maior parte das amostras previstas corretamente em cada classe, com acurácia, sensibilidade e especificidade de 91,50%, possuindo 549 amostras previstas corretamente e 51 com erros em cada classe.

A Figura 40(b) apresenta a matriz de confusão para o classificador kNN usando o ponto de corte 2, com acurácia maior do que o ponto de corte 1. Neste ponto de corte temos uma acurácia de 91,75%, porém este limiar é conservador quando comparado ao ponto de corte anterior, pois um número menor de amostras da classe "Com risco de queda" são previstas corretamente e, consequentemente, tem-se menos falsos positivos. O ponto de corte 2 tem sensibilidade de 90,83% e especificidade de 92,67%. Sobre as amostras da classificadas como "Com risco de queda" no ponto de corte 2, por ser mais conservador, apresenta 545 registros verdadeiros positivos e 44 falsos positivos, com uma pequena diferença de amostras verdadeiras positivas e falso positivas em relação ao ponto de corte 1, como mostra a Figura 40(c).

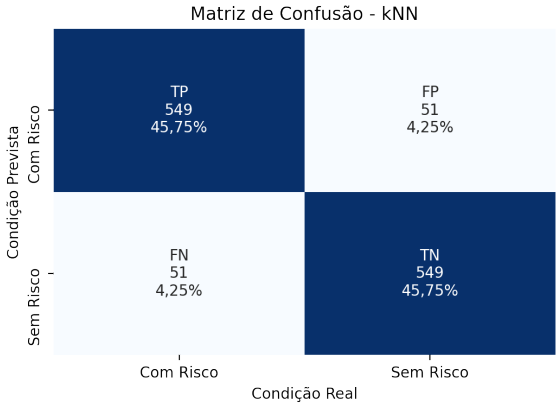

Ponto de Corte 1 = 0,021; Acurácia = 91,50%;

TPR = 91,50%; TNR = 91,50%; FPR = 8,50%; FNR = 8,50%

(a) Ponto de Corte 1.

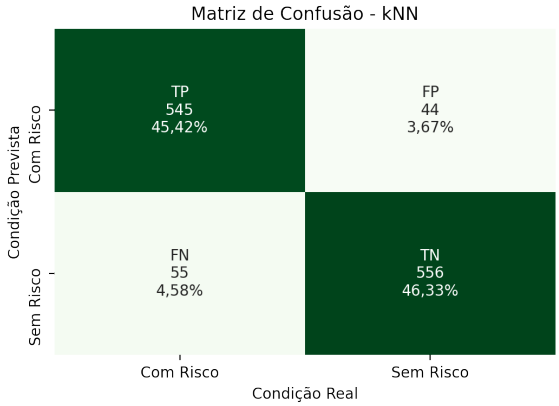

Ponto de Corte 2 = 0,022; Acurácia = 91,75%;

TPR = 90,83%; TNR = 92,67%; FPR = 7,33%; FNR = 9,17%

(b) Ponto de Corte 2.

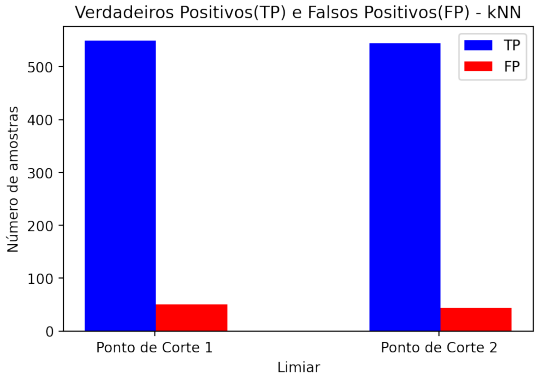

(c) Amostras previstas na classe "Com risco de queda".

Figura 40: Matriz de Confusão e Amostras TP e FP para os pontos de corte no classificador baseado em kNN para $k = 3$ - validação cruzada *k-Fold* - 3^a partição.

3.1.5 Análise dos Resultados do Classificador kNN

O desempenho do classificador é medido a partir da acurácia, o percentual de amostras classificadas corretamente pela quantidade total de amostras a serem classificadas. Como o desempenho do classificador é avaliado usando classes balanceadas, podemos avaliar a acurácia, sem favorecer nenhuma classe.

Quando aplicada a validação *Hold-out*, obtém-se a acurácia no ponto de corte 1 de 86,17% e no ponto de corte 2 de 87,33%. A validação cruzada *k-Fold*, com divisões do conjunto de amostras de CSI da classe "Sem risco de queda", possibilita treinar e testar o classificador kNN com novos registros de CSI. Obtém-se a acurácia média de 75,30% no ponto de corte 1 e no ponto de corte 2 de 77,18%. A Tabela 8 apresenta o resumo das acurácias nos pontos de corte quando aplicados os dois tipos de validação.

Tabela 8: Acurácia nos dois pontos de corte das amostras de risco no Classificador baseado em kNN para $k = 3$.

Grupos	**Acurácia**	
	Ponto de Corte 1	**Ponto de Corte 2**
Hold-out	86,17%	87,33%
k-Fold	75,30%	77,18%

A Figura 41 apresenta a distribuição das distâncias das amostras nas classes "Sem risco de queda" e "Com risco de queda".

Para os registros "Sem risco de queda", observam-se menores valores de distância média e sua distribuição está mais concentrada, menos dispersa, o que se traduz em menos *outliers*. Isso pode ser visto nos dois métodos de validação, *Hold-out* e *k-Fold* nas segunda e terceira partições detalhadas na seção anterior. Os registros "Com risco de queda" apresentam maiores valores de distância média e mais *outliers*, com maior dispersão nas amostras, para os dois métodos de validação.

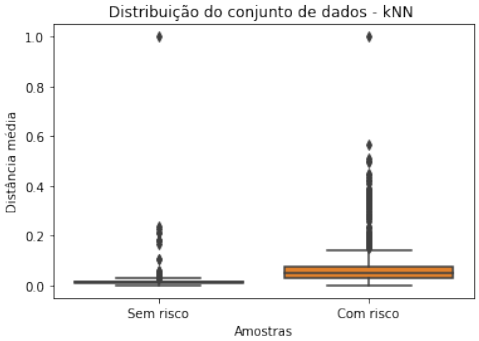

(a) Validação *Hold-out*

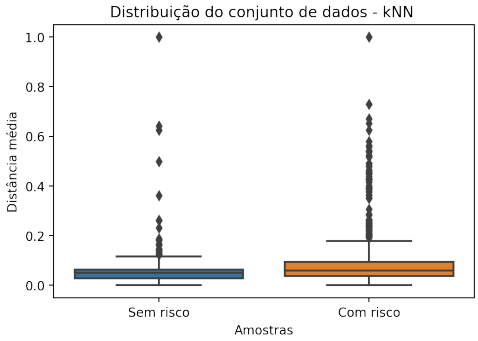

(b) Validação cruzada *k-Fold* - 2^a partição

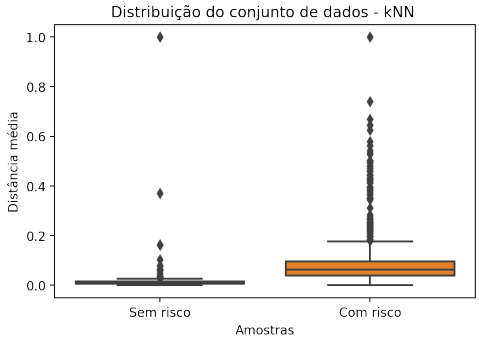

(c) Validação cruzada *k-Fold* - 3^a partição

Figura 41: Distribuição do conjunto de dados no classificador baseado em kNN para $k = 3$ para os diferentes métodos de validação.

3.2 **Classificador Baseado em PCA**

A PCA é uma técnica que explica a estrutura de variância e covariância de um conjunto de variáveis com o objetivo de redução de dimensionalidade e a interpretação de dados [67]. O classificador baseado em PCA reduz a dimensão dos dados. Nesse caso, as amostras de CSI de 128 subportadoras OFDM são compactadas usando poucas componentes principais que mantêm as características mais importantes do conjunto de dados.

A variância explicada, mencionada na subseção 2.3.3, permite determinar o número de CPs. Dessa forma, é preciso observar a partir de quantas CPs a inclinação da curva de variância explicada se aproxima de zero. As CPs restantes pouco acrescentarão ao conjunto de dados e podem ser desconsideradas.

No classificador baseado em PCA, efetua-se a redução de dimensionalidade do vetor de entrada para esse número de CPs. A partir delas, reconstrói-se o vetor de entrada, aplicando-se a operação inversa da PCA, que permite retornar os dados de componentes principais à dimensão original. Para a detecção de anomalia ou não em uma amostra de CSI, calcula-se o erro de reconstrução - o erro médio quadrático (MSE – *Mean Squared Error*) entre a CSI original e sua versão reconstruída pela PCA. Se o erro for grande, dizemos que temos uma anomalia.

Um exemplo semelhante é encontrado em [40] com o uso da PCA para a detecção de anomalias. Como as CPs são obtidas a partir da classe “Sem risco de queda”, espera-se que as amostras com alto erro de reconstrução indiquem anomalias e, portanto, risco de queda. Assim, a aplicação de um ponto de corte com erro de reconstrução aceitável permite diferenciar entre situações normais (“Sem risco de queda”) e anômalas (“Com risco de queda”).

3.2.1 Diagrama de Blocos da PCA

A Figura 42 mostra o diagrama de blocos do classificador baseado em PCA para detecção de quedas a partir da CSI.

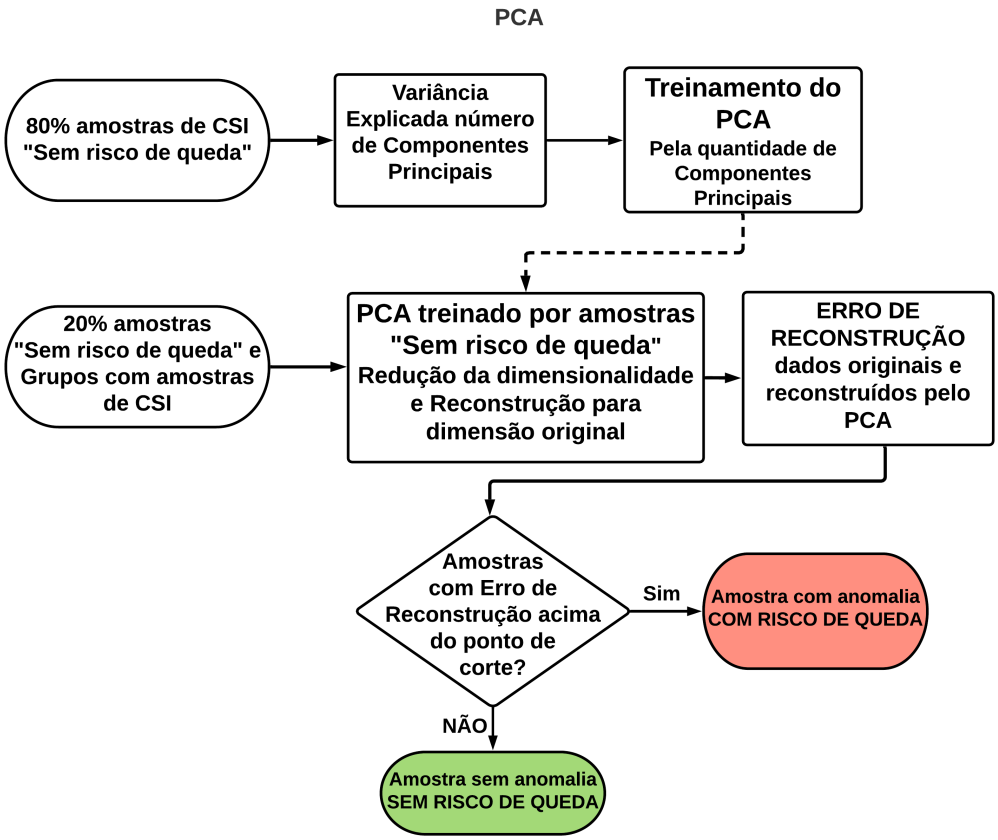

Figura 42: Representação do Classificador baseado em PCA.

3.2.2 Pseudocódigo do Classificador PCA

O pseudo-código nos Algoritmo 3 para treino e Algoritmo 4 para teste do classificador baseado em PCA.

Algoritmo 3: PCA Treinamento

Dados: 80 % das amostras **"Sem risco de queda"**(2400 registros);
Resultado: Treinar o Classificador PCA;
1: Normalizar as amostras CSI por Max-Min;
2: Obter Variância Explicada suficientes para conjunto de dados originais ;
3: Reduzir o conjunto de dados originais pelo número de Componentes Principais;

Algoritmo 4: PCA Teste

Dados: 20 % das amostras **"Sem risco de queda"**(600 registros);
Dados: Amostras **"Com risco de queda"**(600 registros);
Resultado: Detectar amostras de CSI com anomalias e risco de queda;
1: Normalizar as amostras CSI por Max-Min;
2: Reduzir as 128 variáveis originais para as componentes principais;
3: Reconstruir as componentes principais para a dimensão original dos dados;
4: Calcular o Erro de reconstrução (MSE) entre as amostras originais e as reconstruídas pela PCA;
5: Identificar as amostras com alto erro de reconstrução - amostras com risco de queda;

3.2.3 Descrição dos Testes do Classificador PCA

A Figura 42 ilustra o diagrama da aplicação da PCA para a detecção de risco de queda das amostras de CSI. Com 80% das amostras da classe "Sem risco de queda" obtém-se o gráfico da variância explicada correspondente a 95% da energia do conjunto de dados originais.

Observa-se através da Figura 43 a quantidade de CPs suficientes para a representação do conjunto de dados originais. Em seguida, a PCA é treinado para a redução de dimensionalidade de 128 variáveis originais para a quantidade especificada de CPs.

A Figura 43 indica que 3 CPs representam 89,59% da energia do sinal original e as componentes restantes acrescentam pouca informação aos dados originais. Em seguida, é aplicada a redução de dimensionalidade através da PCA de 128 variáveis que corresponde a cada subportadora OFDM para 3 CPs. Em seguida, por meio do processo inverso da PCA ocorre a reconstrução de 3 CPs para 128 variavéis.

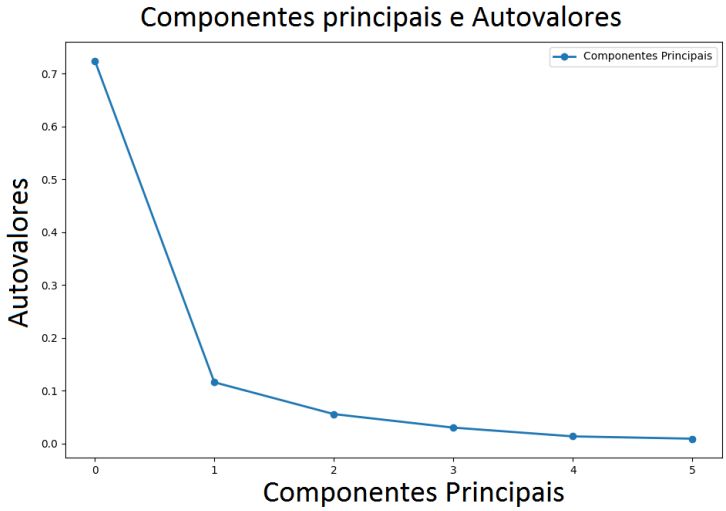

Figura 43: Gráfico para análise de componentes principais e autovalores no classificador baseado em PCA.

3.2.4 Resultados

Nesta subseção estão disponíveis os resultados do Classificador PCA. São aplicados os dois pontos de cortes nos métodos de validação *Hold-out* e cruzada *k-Fold* para analisar o funcionamento do classificador e identificar as amostras "Com risco de queda".

3.2.4.1 Validação *Hold-out*

A Figura 44 apresenta as curvas de sensibilidade, especificidade e acurácia nos dois pontos de corte e a Figura 45 mostra a localização dos pontos de corte. Observa-se que os pontos de corte são próximos, e devido às suas localizações na Curva ROC, verifica-se que o ponto de corte 1 é conservador quando comparado ao ponto de corte 2 que tem sensibilidade maior que especificidade. Os dois pontos de corte apresentam acurácia acima de 90%.

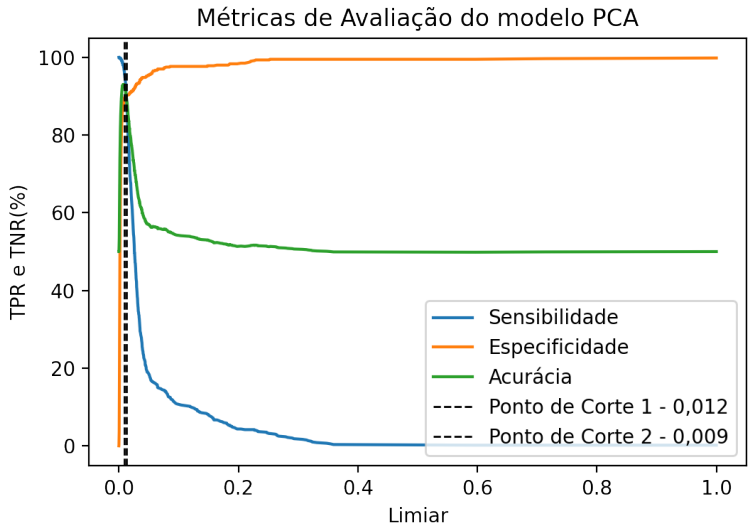

Figura 44: Localização dos pontos de corte no classificador baseado em PCA para 3 CPs - validação *Hold-out*.

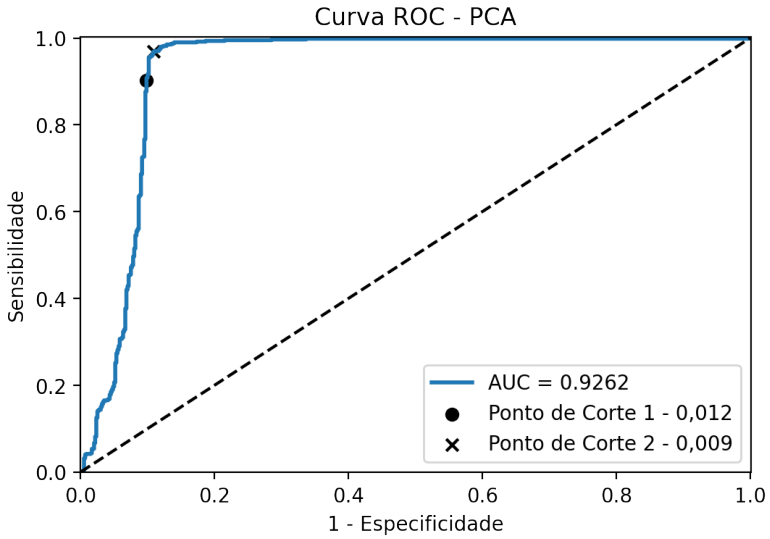

Figura 45: Localização dos pontos de corte na Curva ROC no classificador baseado em PCA para 3 CPs - validação *Hold-out*.

A Figura 46(a) apresenta a matriz de confusão do classificador PCA no ponto de corte 1, com sensibilidade, especificidade e acurácia iguais a 90,17%. Neste ponto de corte. o classificador PCA prevê 514 amostras corretamente e apresenta 59 amostras com erros em cada classe.

A Figura 46(b) mostra o ponto de corte 2 com sensibilidade de 96,83%, especificidade de 89,17% e acurácia de 93,00%. Como este ponto de corte é considerado liberal

quando comparado ao ponto de corte anterior, são produzidas mais amostras verdadeiro positivas e consequentemente mais amostras falso positivas. São previstas corretamente na classe "Com risco de queda" 581 amostras porém apresenta 65 amostras com erros.

A Figura 46(c) mostra que o ponto de corte 2 prevê corretamente 40 amostras a mais da classe "Com risco de queda" (verdadeiros positivos) que o ponto de corte 1. Em relação aos falsos positivos, ou seja, amostras com erros, a diferença é de apenas 6 amostras. Nesta situação, a escolha por um ponto de corte liberal permite identificar mais amostras com anomalia ou risco de queda, com pequena diferença em relação aos erros.

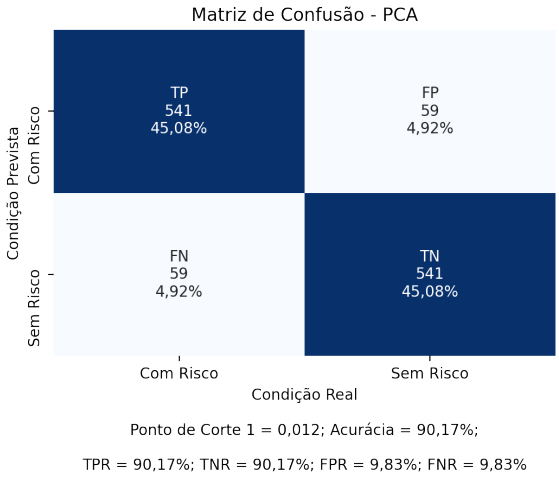

(a) Ponto de Corte 1

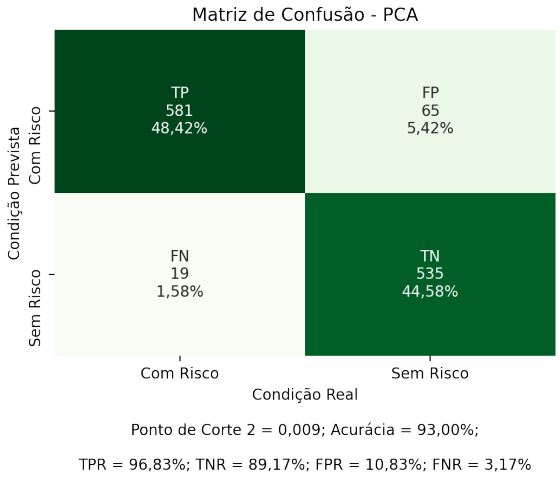

(b) Ponto de Corte 2

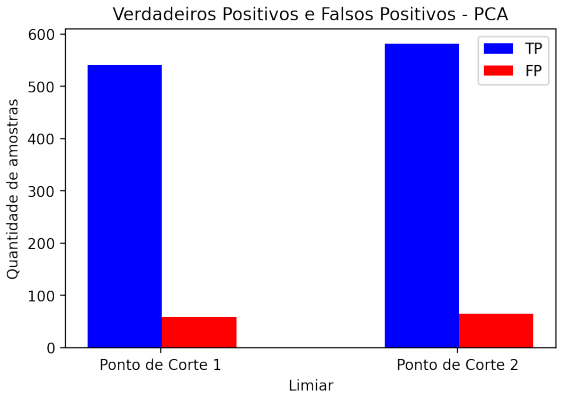

(c) Amostras previstas na classe "Com risco de queda".

Figura 46: Matriz de Confusão e Amostras TP e FP para os pontos de corte no classificador baseado em PCA para 3 CPs - validação *Hold-out*.

3.2.4.2 Validação cruzada *k-Fold*

A Tabela 9 apresenta os resultados dos testes com as amostras da classe "Com risco de queda" e com amostras de testes da classe "Sem risco de queda" no ponto de corte 1, e a Tabela 10, no ponto de corte 2.

Tabela 9: Resultados dos testes na validação cruzada *k-Fold* para Classificador baseado em PCA para 3 CPs no ponto de corte 1.

Teste	**Ponto de Corte 1**					
Partição	**Ponto de Corte**	**TPR**	**TNR**	**FPR**	**FNR**	**Acurácia**
1	0,012	90,17%	90,17%	9,83%	9,83%	90,17%
2	0,015	82,00%	82,00%	18,00%	18,00%	82,00%
3	0,012	90,33%	90,33%	9,67%	9,67%	90,33%
4	0,013	89,17%	89,17%	10,83%	10,83%	89,17%
5	0,014	84,83%	84,83%	15,17%	15,17%	84,83%
Acurácia média	**87,29%**					

Tabela 10: Resultados dos testes na validação cruzada *k-Fold* para Classificador baseado em PCA para 3 CPs no ponto de corte 2.

Teste	**Ponto de Corte 2**					
Partição	**Ponto de Corte**	**TPR**	**TNR**	**FPR**	**FNR**	**Acurácia**
1	0,009	96,83%	89,17%	10,83%	3,17%	93,00%
2	0,013	87,50%	78,33%	21,67%	12,50%	82,92%
3	0,008	97,83%	89,17%	10,83%	2,17%	93,50%
4	0,009	97,33%	87,00%	13,00%	2,67%	92,17%
5	0,011	93,50%	79,67%	20,33%	6,50%	86,58%
Acurácia média	**89,69%**					

A partir dos resultados apresentados nas Tabelas 9 e 10, nota-se que a cada partição, o classificador apresenta diferentes resultados de acordo com as amostras de CSI "Sem risco de queda" aplicadas para treinamento e teste. A acurácia média obtida da validação cruzada *k-Fold* é de 87,29% no ponto de corte 1 e de 89,69% no ponto de corte 2.

Os resultados apresentados na validação cruzada *k-Fold* do classificador PCA indicam que na 2^a partição obtém a menor acurácia, de até 82,92% nos dois pontos de corte e na 3^a partição, obteve-se a maior acurácia, acima de 90%, para ambos os pontos de corte. Nesta subseção são detalhados os resultados da segunda e terceira partições.

A Figura 47 ilustra as curvas de sensibilidade, especificidade e acurácia e a Figura 48 mostra a disposição dos pontos de corte na Curva ROC na segunda partição.

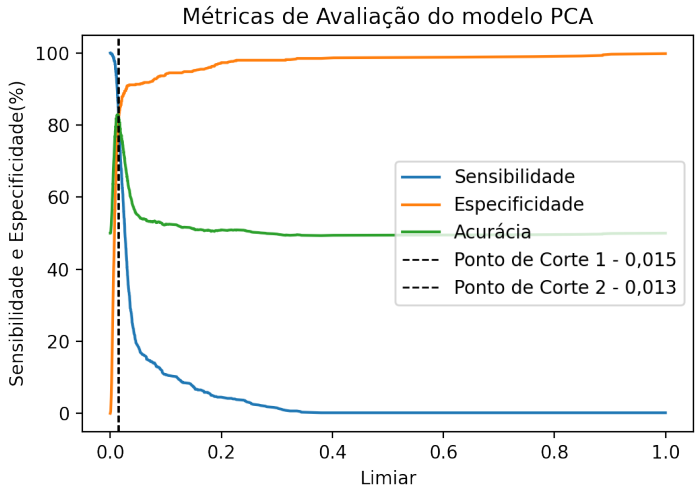

Figura 47: Localização dos pontos de corte no classificador baseado em PCA para 3 CPs - validação cruzada *k-Fold* - 2^a partição.

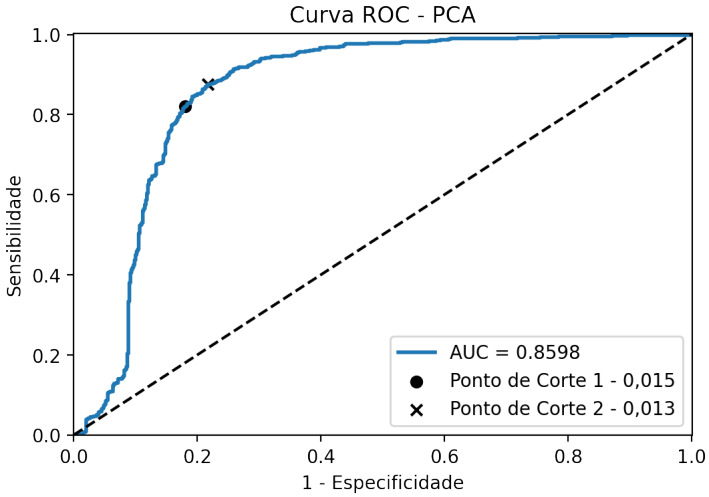

Figura 48: Localização dos pontos de corte na Curva ROC no classificador baseado em PCA para 3 CPs - validação cruzada *k-Fold* - 2^a partição.

A Figura 49(a) mostra a matriz de confusão para o ponto de corte 1, com acurácia, sensibilidade e especificidade de 82,00%, com 492 amostras corretas e 108 erros.

A Figura 49(b) apresenta a matriz de confusão para no ponto de corte 2. Este ponto de corte é liberal se comparado ao ponto de corte 1, com mais amostras verdadeiro positivas e consequentemente mais amostras falso positivas. São previstas na classe "Com risco de queda" 525 amostras corretamente e 130 amostras com erros. O ponto de corte 2 tem acurácia de 82,92%, com pouca diferença da acurácia obtida no ponto de corte anterior e possui sensibilidade de 87,50% e especificidade de 78,33%. A Figura 49(c) mostra as amostras previstas na classe "Com risco de queda" nos dois pontos de corte. O ponto de corte 2 prevê corretamente mais amostras mas também apresentará mais erros (falsos positivos) do que o ponto de corte 1.

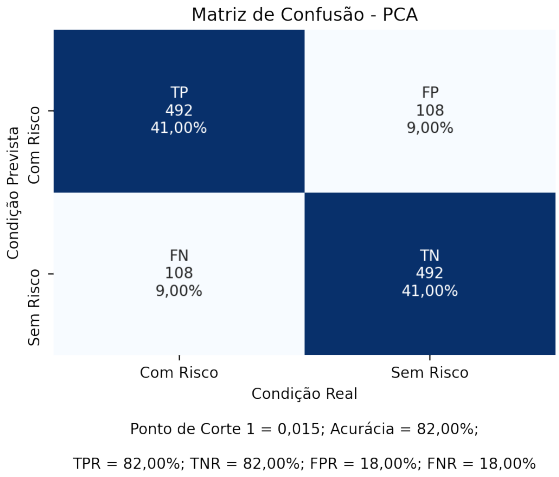

(a) Ponto de Corte 1.

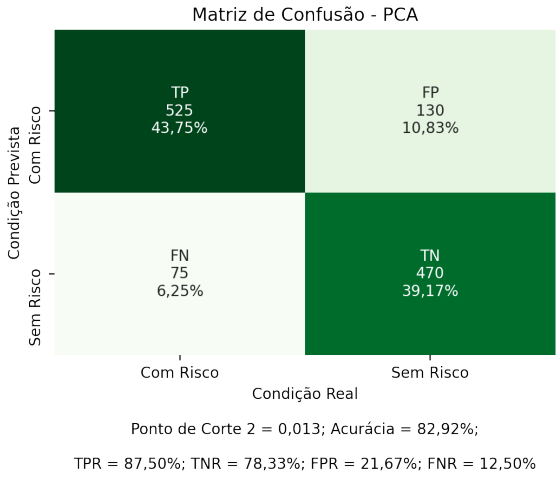

(b) Ponto de Corte 2.

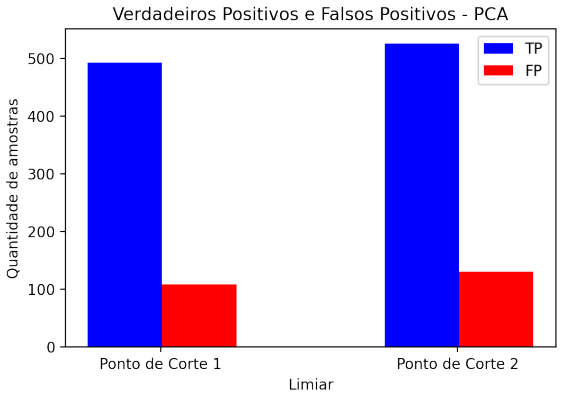

(c) Amostras previstas na classe "Com risco de queda".

Figura 49: Matriz de Confusão e Amostras TP e FP para os pontos de corte no classificador baseado em PCA para 3 CPs - validação cruzada *k-Fold* - 2^a partição.

A Figura 50 ilustra as curvas de sensibilidade, especificidade e acurácia e a Figura 51 mostra a disposição dos pontos de corte na Curva ROC na terceira partição, quando

se obteve a maior acurácia.

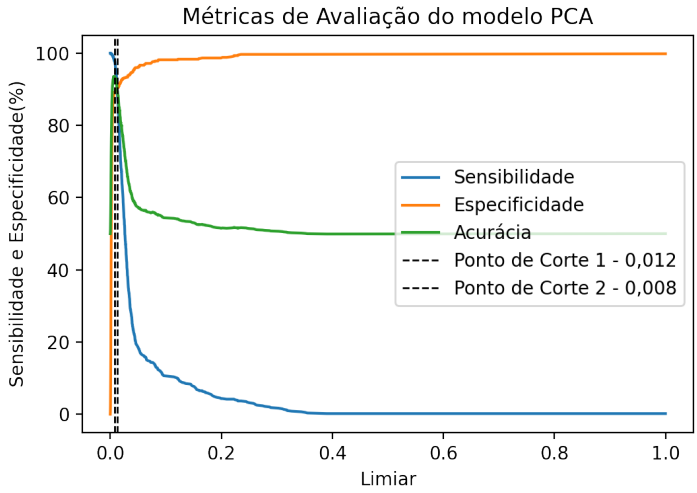

Figura 50: Localização dos pontos de corte no classificador baseado em PCA para 3 CPs - validação cruzada *k-Fold* - 3^a partição.

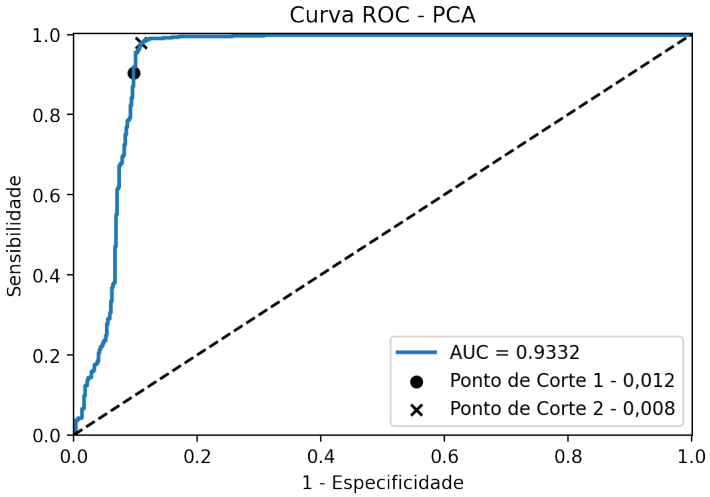

Figura 51: Localização dos pontos de corte na Curva ROC no classificador baseado em PCA para 3 CPs - validação cruzada *k-Fold* - 3^a partição.

A Figura 52(a) mostra a matriz de confusão para o ponto de corte 1, com a maioria das amostras previstas corretamente em cada classe, com acurácia, sensibilidade e especificidade de 90,33%, com 542 amostras corretas e 58 com erros.

A Figura 52(b) apresenta a matriz de confusão para o classificador PCA no ponto de corte 2. Este ponto de corte é liberal se comparado ao ponto de corte 1, com mais amostras verdadeiro positivas e consequentemente mais amostras falso positivas. São

previstas na classe “Com risco de queda” 587 amostras corretamente e 65 amostras com erros. O ponto de corte 2 tem acurácia de 93,50%, maior que a obtida no ponto de corte anterior como esperado, bem como sensibilidade de 97,83% e especificidade de 89,17%. A Figura 52(c) mostra as amostras previstas na classe “Com risco de queda”. O ponto de corte 2 é capaz de prever corretamente 45 amostras a mais que o ponto de corte 1 e com 7 com diferença de 7 amostras com erros em relação ao ponto de corte 1.

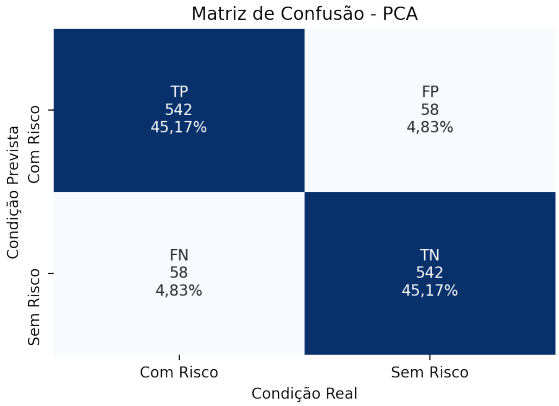

(a) Ponto de Corte 1.

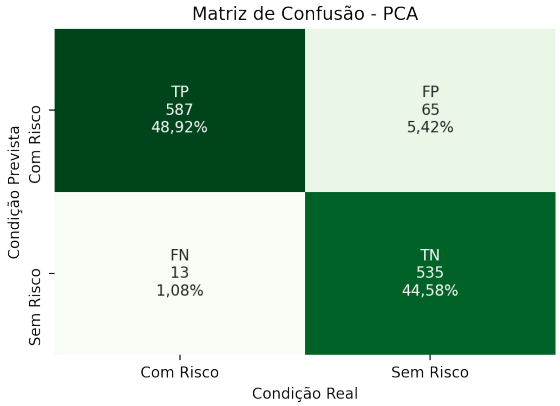

(b) Ponto de Corte 2.

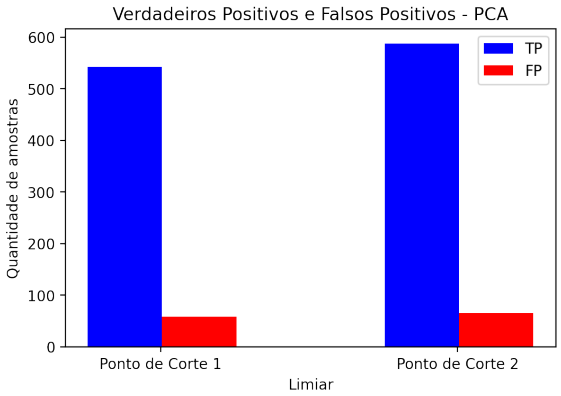

(c) Amostras previstas na classe “Com risco de queda”.

Figura 52: Matriz de Confusão e Amostras TP e FP para os pontos de corte no classificador baseado em PCA para 3 CPs - validação cruzada *k-Fold* - 3^a partição.

3.2.5 Análises dos Resultados do Classificador PCA

A análise é realizada a partir da acurácia, ou seja, o percentual de amostras classificadas corretamente. A Tabela 11 mostra a acurácia obtida em cada validação nos dois pontos de corte.

Tabela 11: Acurácia nos dois pontos de corte das amostras de risco no Classificador baseado em PCA para 3 CPs.

Grupos	**Acurácia**	
	Ponto de Corte 1	**Ponto de Corte 2**
Hold-out	90,17%	93,00%
k-Fold	87,29%	89,69%

Na validação *Hold-out*, obtêm-se uma acurácia no ponto de corte 1 de 90,17% e no ponto de corte 2, de 93,00%. A validação cruzada *k-Fold* apresenta acurácias médias de 87,29% e 89,69% nos pontos de corte 1 e 2, respectivamente. Observa-se que os valores de acurácia são próximos nos dois pontos de corte para cada método de validação, mas a acurácia é maior na validação *Hold-out*.

A Figura 53 mostra a distribuição do erro de reconstrução das amostras das classes "Sem risco de queda" e "Com risco de queda". Para o erro de reconstrução das amostras "Sem risco de queda" observa-se menores valores quando comparado ao relacionado as amostras "Com risco de queda". A distribuição do erro na classe "Sem risco de queda" apresenta uma menor dispersão do que a classe "Com risco de queda" na validação *Hold-out* e na cruzada *k-Fold* nas partições apresentadas na subseção anterior.

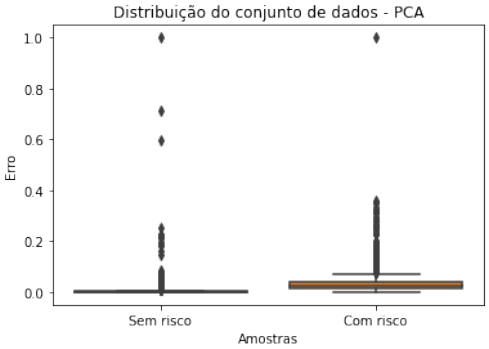

(a) Validação *Hold-out*

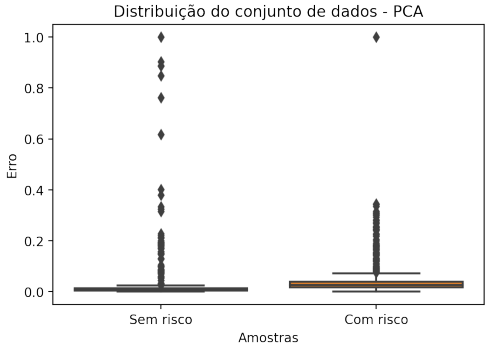

(b) Validação cruzada *k-Fold* - 2^a partição

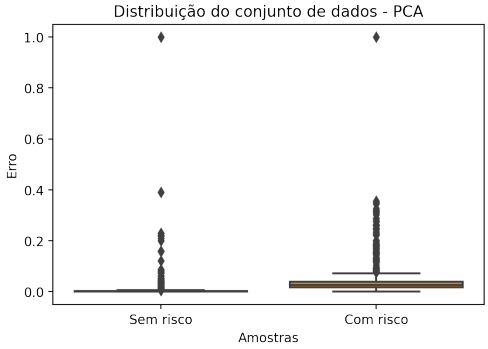

(c) Validação cruzada *k-Fold* - 3^a partição

Figura 53: - Distribuição do conjunto de dados no classificador baseado em PCA para 3 CPs para os diferentes métodos de validação.

3.3 **Classificador Baseado em Autoencoder**

Usamos o Autoenconder para detecção de anomalias, as amostras "Com risco de queda", tal qual com a PCA. O Autoenconder é treinado para codificar bem amostras de CSI advindas da situação "Sem risco de queda". A abordagem é análoga à empregada com PCA, porém, devido ao processamento não-linear realizado pelo Autoenconder, espera-se, a princípio, uma maior capacidade de compactação/redução de dimensionalidade e possivelmente um melhor desempenho desse detector. Procedimento similar com uso do Autoencoder é aplicado em [48] para a detecção de anomalias.

3.3.1 Diagrama de Blocos do Autoencoder

A Figura 54 mostra o diagrama de blocos do classificador baseado em Autoencoder para detecção de quedas com amostras da CSI.

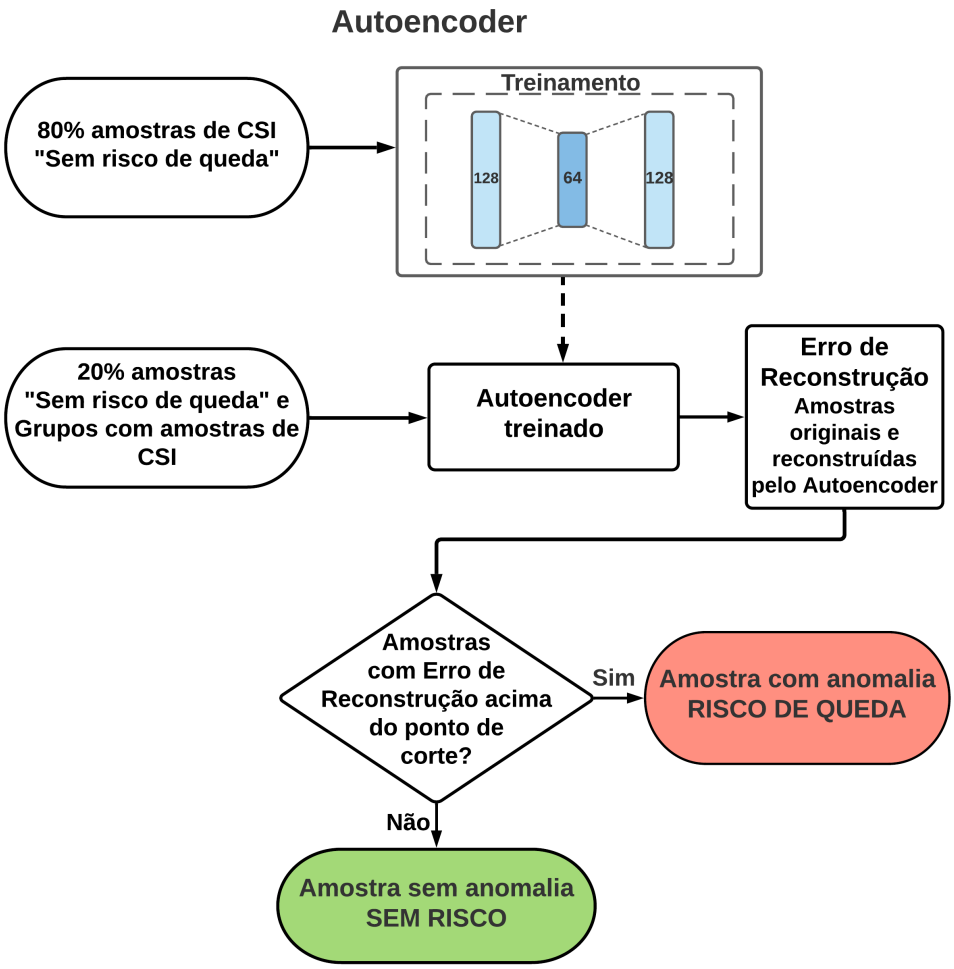

Figura 54: Representação do Classificador baseado em Autoencoder.

3.3.2 Pseudocódigo do Classificador Autoencoder

Os pseudo-códigos de treinamento e teste do classificador baseado em Autoencoder são descritos nos Algoritmos 5 e 6, respectivamente.

Algoritmo 5: Autoencoder Treinamento

Dados: 80 % das amostras **"Sem risco de queda"**(2400 registros);
Resultado: Treinar o Classificador Autoencoder;
1: Normalizar as amostras de CSI por Max-Min;

Algoritmo 6: Autoencoder Teste

Dados: 20 % das amostras **"Sem risco de queda"**(600 registros);
Dados: Amostras **"Com risco de queda"**(600 registros);
Resultado: Detectar de amostras de CSI com anomalias e risco de queda;
1: Normalizar das amostras de CSI por Max-Min;
2: Processar amostras de CSI pelo Autoencoder treinado;
3: Calcular o Erro de reconstrução (MSE) entre as amostras originais e as reconstruídas pelo Autoencoder;
4: Identificar as amostras com alto erro de reconstrução - amostras com risco de queda;

3.3.3 Descrição dos Testes do Classificador Autoencoder

Neste trabalho, o classificador baseado em Autoencoder é configurado como mostra a Figura 54, com amostras da CSI das 128 subportadoras OFDM recebidas no codificador, onde ocorre a redução de dimensionalidade pelas camadas intermediárias até a reconstrução para a dimensão original pelo decodificador.

São aplicados três modelos de Autoenconder, com diferentes números de neurônios e camadas. O Autoencoder é treinado por 20 épocas, com *batch size* igual a 128, com uso do otimizador *Adam* e *Early Stopping*. Caso não ocorra o decréscimo da perda por 2 épocas o treinamento é interrompido. Os hiperparâmetros foram escolhidos devido a testes aplicados ao Autoencoder, de modo que a configuração definida corresponde àquela de menor variação nos resultados.

Os testes foram aplicados a três modelos com os seguintes formatos: Modelo 1 com sete camadas de 128-64-32-16-32-64-128 neurônios, o Modelo 2 com cinco camadas de 128-64-32-64-128 neurônios e o Modelo 3 com três camadas de 128-64-128 neurônios. São apresentados nesta seção os resultados do modelo de Autoencoder com melhor desempenho, em termos de AUC.

Para a detecção de anomalias ou amostras "Com risco de queda", o Autoenconder é treinado com amostras de CSI da situação "Sem risco de queda", que são separadas em 80% para o treinamento do classificador e em 20% para o teste.

3.3.4 Resultados

Esta subseção mostra os resultados do classificador baseado no Autoencoder. A Figura 55 mostra o desempenho obtido em cada modelo para o classificador Autoencoder e

o modelo 3 é escolhido por apresentar maior AUC.

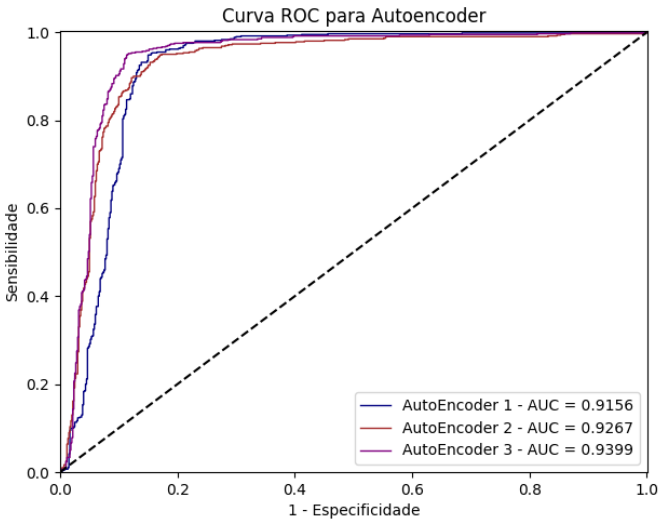

Figura 55: Curva ROC do Autoencoder para os 3 Modelos.

3.3.4.1 Validação *Hold-out*

A Figura 56 mostra as curvas de sensibilidade, especificidade e acurácia e a Figura 57 apresenta os pontos de corte aplicados a curva ROC.

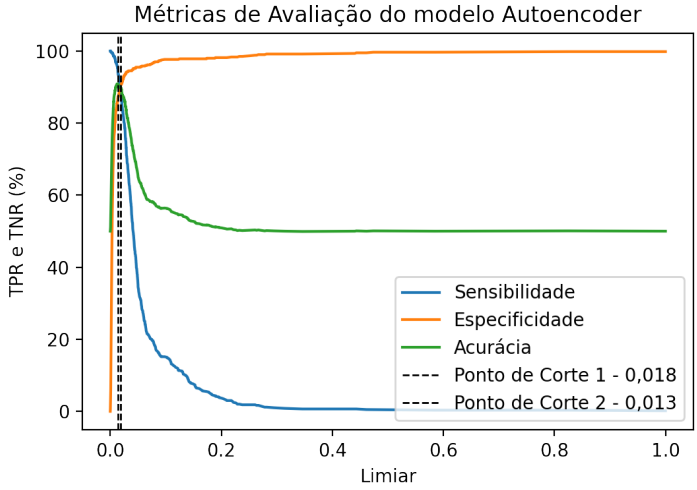

Figura 56: Localização dos pontos de corte no classificador baseado em Autoencoder - modelo 3 - validação *Hold-out*.

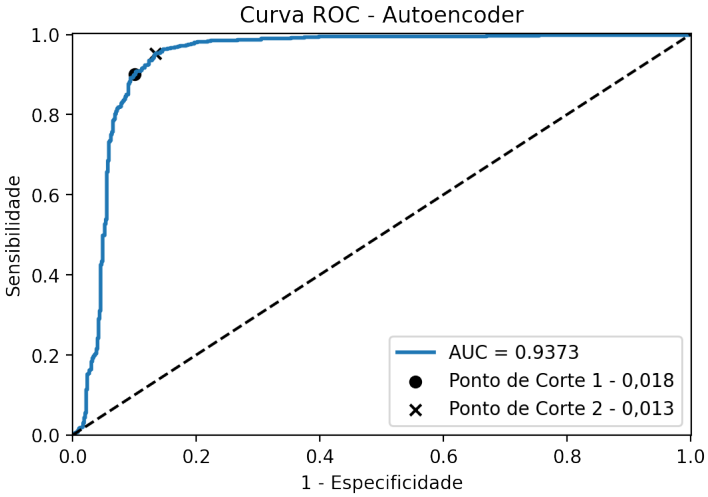

Figura 57: Localização dos pontos de corte na Curva ROC no classificador baseado em Autoencoder - modelo 3 - validação *Hold-out*.

A Figura 58(a) apresenta a matriz de confusão do ponto de corte 1, com sensibilidade, especificidade e acurácia iguais a 90,00%. O classificador baseado em Autoencoder prevê corretamente 540 amostras e apresenta 60 amostras com erros em cada classe.

O ponto de corte 2 apresentado na Figura 58(b), tem sensibilidade de 95,17%, especificidade de 86,67% e acurácia de 90,92%. O ponto de corte 2 é visto como liberal em comparação ao ponto de corte 1, então este ponto apresenta mais amostras verdadeiro positivas e portanto, produz mais amostras falso positivas. São previstas corretamente na classe "Com risco de queda" 571 amostras mas com 80 amostras com erro.

A Figura 58(c) mostra a diferença dos erros e acertos em cada ponto de corte e observa-se que para o ponto de corte 2 obtêm-se 31 amostras verdadeiro positivas a mais que para o ponto de corte 1. Em relação as amostras com erros, ou falsos positivos, a diferença entre os pontos de corte é de 20 amostras. Como o ponto de corte 2 mais liberal, 80 amostras apresentam erros, enquanto 60 erros são apresentados no ponto de corte 1.

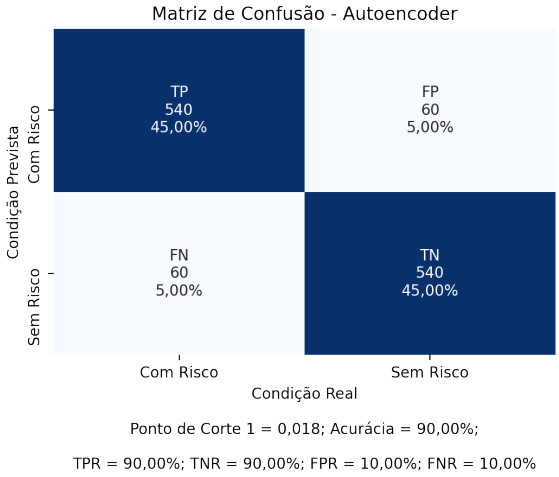

(a) Ponto de Corte 1

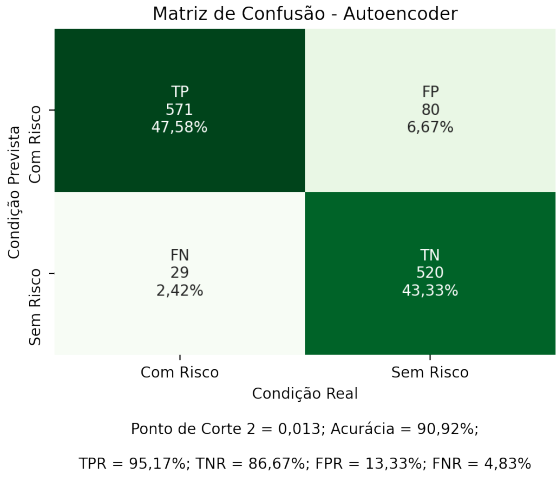

(b) Ponto de Corte 2

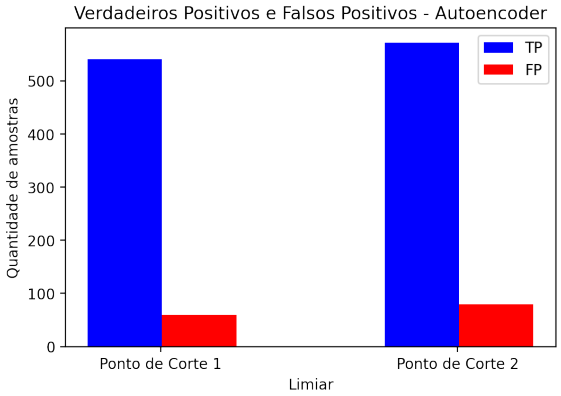

(c) Amostras previstas na classe "Com risco de queda".

Figura 58: Matriz de Confusão e Amostras TP e FP para os pontos de corte no classificador baseado em Autoencoder - modelo 3 - validação *Hold-out*

3.3.4.2 Validação cruzada *k-Fold*

A Tabela 12 apresenta os resultados dos testes com as amostras da classe "Com risco de queda" e com os registros de testes da classe "Sem risco de queda" nos ponto de corte 1 e a Tabela 13 no ponto de corte 2.

Tabela 12: Resultados da validação cruzada *k-Fold* para Classificador baseado em Autoencoder modelo 3 no ponto de corte 1.

Teste	**Ponto de Corte 1**					
Partição	**Ponto de Corte**	**TPR**	**TNR**	**FPR**	**FNR**	**Acurácia**
1	0,020	90,50%	90,50%	9,50%	9,50%	90,50%
2	0,029	81,83%	81,83%	18,17%	18,17%	81,83%
3	0,021	90,67%	90,67%	9,33%	9,33%	90,67%
4	0,020	86,33%	86,33%	13,67%	13,67%	86,33%
5	0,029	91,50%	91,50%	8,50%	8,50%	91,50%
Acurácia média	**88,17%**					

Tabela 13: Resultados da validação cruzada *k-Fold* para Classificador baseado em Autoencoder modelo 3 no ponto de corte 2.

Teste	**Ponto de Corte 2**					
Partição	**Ponto de Corte**	**TPR**	**TNR**	**FPR**	**FNR**	**Acurácia**
1	0,016	94,83%	89,00%	11,00%	5,17%	91,92%
2	0,021	93,33%	73,17%	26,83%	6,67%	83,25%
3	0,017	94,67%	88,50%	11,50%	5,33%	91,58%
4	0,016	92,67%	83,00%	17,00%	7,33%	87,83%
5	0,022	95,83%	89,67%	10,33%	4,17%	92,75%
Acurácia média	**89,47%**					

Observa-se nas Tabelas 12 e 13 que diferentes resultados são obtidos a cada partição, pois são aplicados para treinamento e teste diferentes conjuntos/blocos de amostras. A acurácia média para as 5 partições é de 88,17% no ponto de corte 1 e 89,47% no ponto de corte 2. Essa subseção mostra os resultados obtidos nas segunda e quinta partição do método de validação cruzada *k-Fold*, quando se obteve menor e maior acurácia, respectivamente.

A Figura 59 mostra as curvas de sensibilidade, especificidade e acurácia e a Figura 60 mostra os dois pontos de corte na Curva ROC. Observa-se acurácia de até 83,25% na segunda partição.

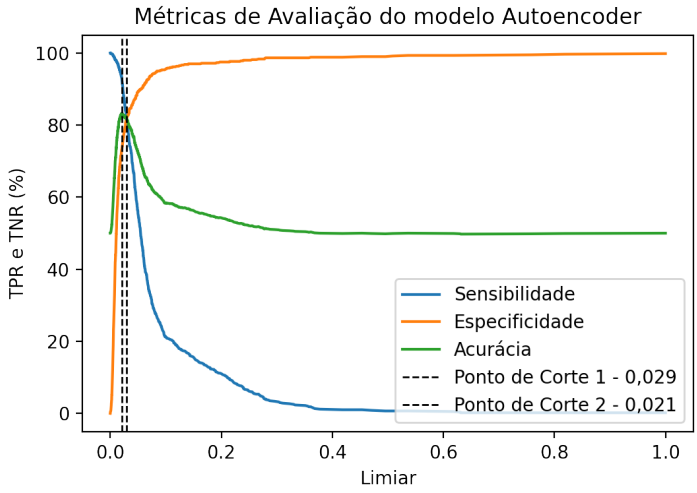

Figura 59: Localização dos pontos de corte para o classificador baseado em Autoencoder - modelo 3 - validação *k-Fold* - 2^a partição.

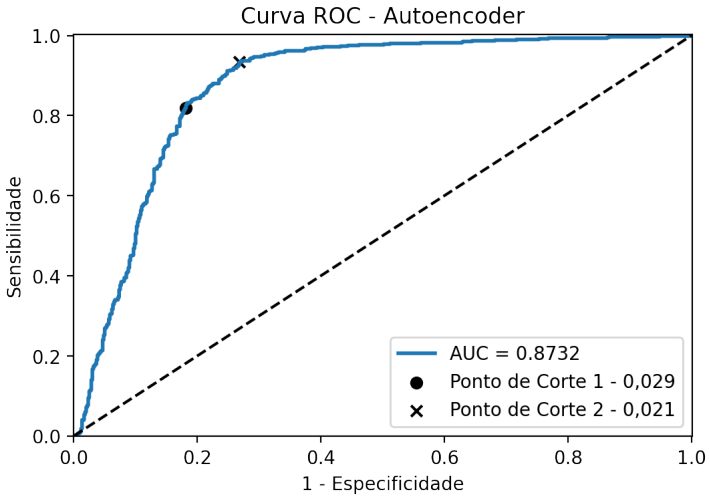

Figura 60: Localização dos pontos de corte na Curva ROC para classificador baseado em Autoencoder - modelo 3 - validação cruzada *k-Fold* - 2^a partição.

A Figura 61(a) mostra a matriz de confusão para o ponto de corte 1, com acurácia, sensibilidade e especificidade iguais a 81,83%, com 491 amostras previstas corretamente e 109 com erros em cada classe.

A Figura 61(b) apresenta a matriz de confusão para o classificador no ponto de corte 2, com acurácia de 83,25%, maior que a acurácia do ponto de corte anterior. O ponto de corte 2 é flexível se comparado ao ponto de corte 1, assim mais apresentará mais amostras verdadeiro positivas e falso positivas. São previstas corretamente 560 amostras da classe "Com risco de queda" e 161 amostras com erros. O ponto de corte 2 tem sensibilidade de 93,33% e especificidade de 73,17%. A Figura 61(c) mostra que o ponto de corte 2 apresenta mais verdadeiros positivos porém apresenta mais falsos positivos em comparação ao ponto de corte 1.

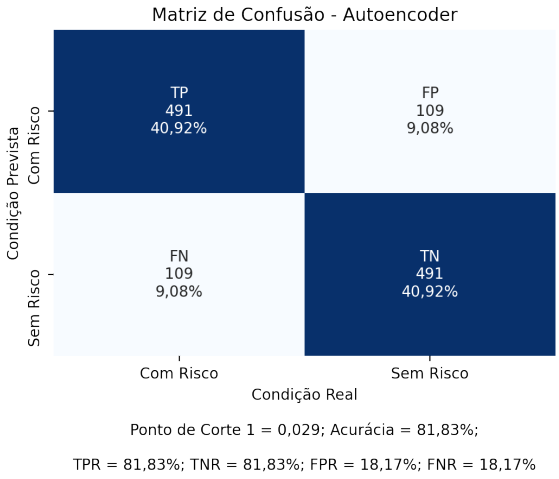

(a) Ponto de Corte 1.

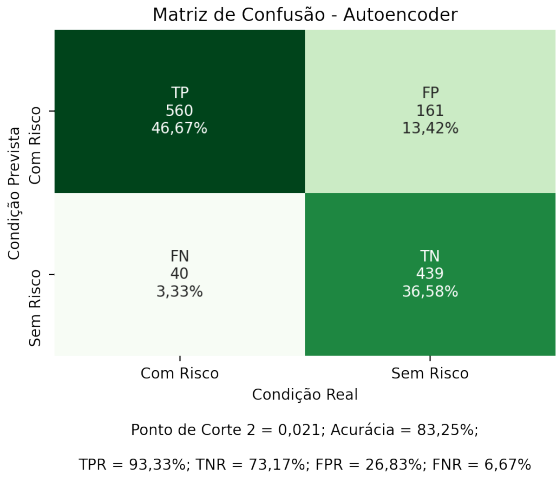

(b) Ponto de Corte 2.

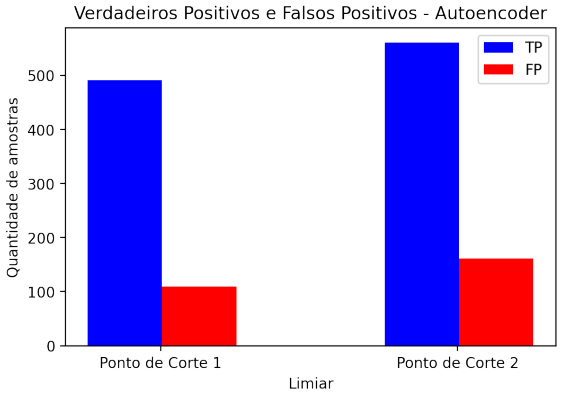

(c) Amostras previstas na classe "Com risco de queda".

Figura 61: Matriz de Confusão e Amostras TP e FP para os pontos de corte no classificador baseado em Autoencoder - modelo 3 - validação cruzada *k-Fold* - 2^a partição.

A Figura 62 mostra as curvas de sensibilidade, especificidade e acurácia e a Figura 63 mostra os dois pontos de corte na Curva ROC na quinta partição quando se observa acurácia acima de 90%.

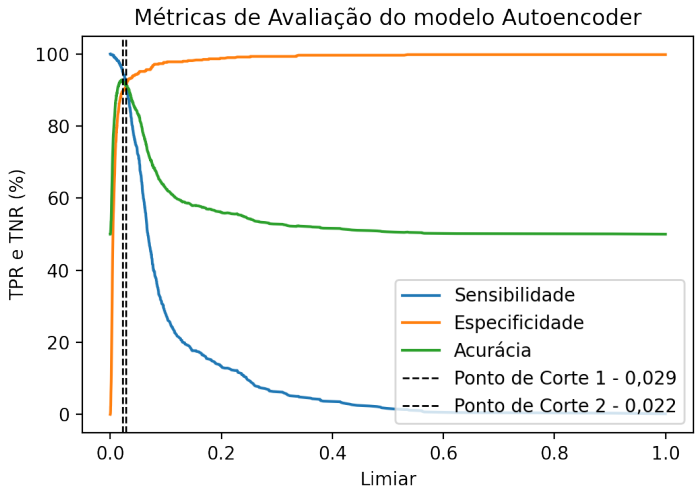

Figura 62: Localização dos pontos de corte para o classificador baseado em Autoencoder - modelo 3 - validação *k-Fold* - 5^a partição.

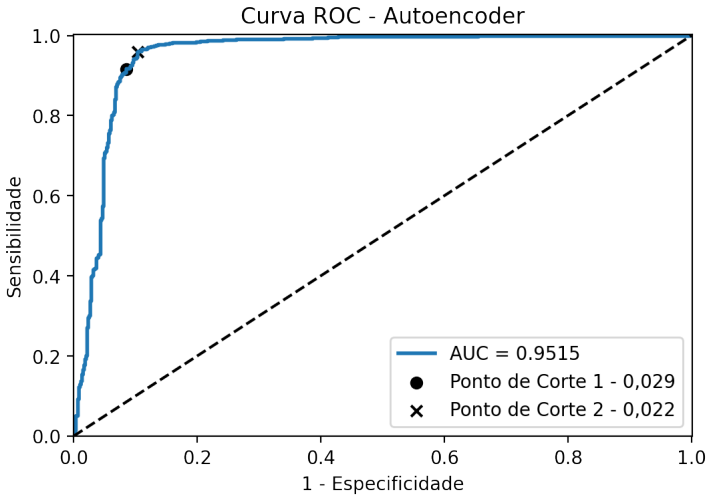

Figura 63: Localização dos pontos de corte na Curva ROC para classificador baseado em Autoencoder - modelo 3 - validação cruzada *k-Fold* - 5^a partição.

A Figura 64(a) mostra a matriz de confusão para o ponto de corte 1, com acurácia, sensibilidade e especificidade iguais a 91,50%, com 549 amostras previstas corretamente e 51 com erros em cada classe.

A Figura 64(b) apresenta a matriz de confusão para o classificador no ponto de corte 2, com acurácia de 92,75%, acurácia maior que a apresentada no ponto de corte anterior. O ponto de corte 2 é flexível quando comparado ao ponto de corte 1, com mais número de amostras verdadeiro positivas e falso positivas. São previstas corretamente 575 amostras da classe "Com risco de queda" e 62 amostras com erros. O ponto de corte 2 tem sensibilidade de 95,83% e especificidade de 89,67%. A Figura 64(c) mostra que o ponto de corte 2 apresenta mais verdadeiros positivos e falsos positivos em comparação ao ponto de corte 1. São 26 amostras com acertos a mais e 11 amostras com erros quando comparado ao ponto de corte 1.

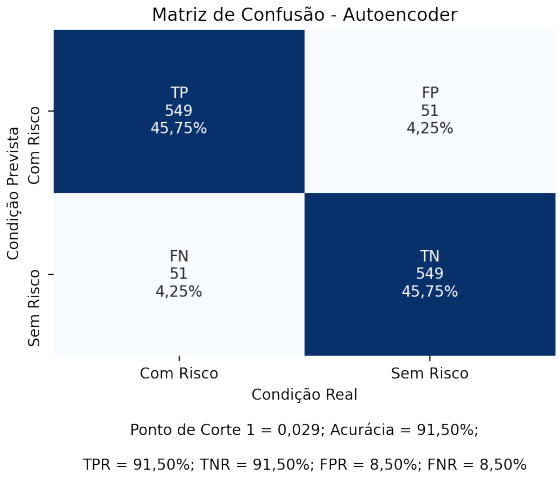

(a) Ponto de Corte 1.

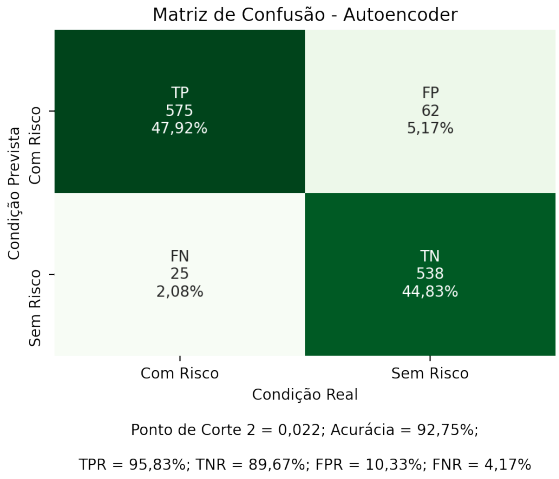

(b) Ponto de Corte 2.

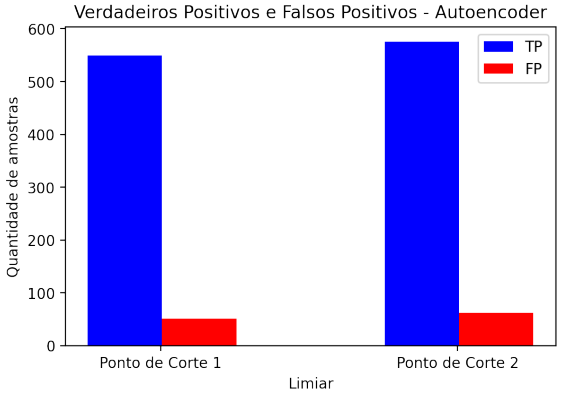

(c) Amostras previstas na classe "Com risco de queda".

Figura 64: Matriz de Confusão e Amostras TP e FP para os pontos de corte no classificador baseado em Autoencoder - modelo 3 - validação cruzada *k-Fold* - 5^a partição.

3.3.5 Análises dos Resultados do Classificador Autoencoder

O desempenho do classificador é avaliado pela acurácia e a Tabela 14 mostra o resultado para cada validação nos dois pontos de corte.

Tabela 14: Acurácia nos dois pontos de corte das amostras de risco no Classificador baseado em Autoencoder - modelo 3.

Grupos	**Acurácia**	
	Ponto de Corte 1	**Ponto de Corte 2**
Validação *Hold-out*	90,00%	90,92%
Validação *k-Fold*	88,17%	89,47%

Na validação *Hold-out*, o classificador tem acurácia no ponto de corte 1 de 90,00%, e no ponto de corte 2, de 90,92%. A validação cruzada *k-Fold* o classificador baseado em Autoencoder tem acurácia média de 88,17% no ponto de corte 1 e 89,47% no ponto de corte 2. Nota-se que a acurácia nos métodos de validação tem valores próximos nos dois pontos de corte, mas a acurácia é maior no método de validação *Hold-out*.

A Figura 65 apresenta a distribuição do erro de reconstrução das amostras das classes "Sem risco de queda" e "Com risco de queda". O erro de reconstrução das amostras "Sem risco de queda" apresenta valores menores em comparação ao erro obtido das amostras "Com risco de queda" para os dois métodos de validação. No método de validação cruzada *k-Fold*, o erro das amostras "Sem risco de queda" apresenta menor dispersão e menos *outliers*. Nas amostras da classe "Com risco de queda", a validação cruzada *k-Fold* apresenta maiores valores do erro de reconstrução e maior dispersão, produzindo mais *outliers*.

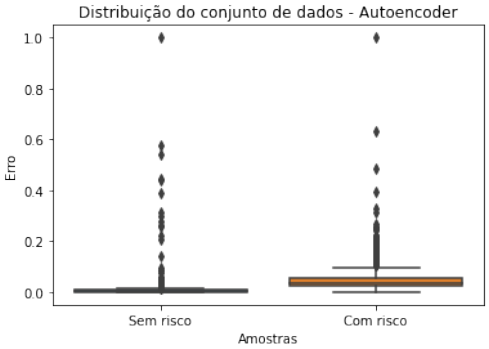

(a) Validação *Hold-out*

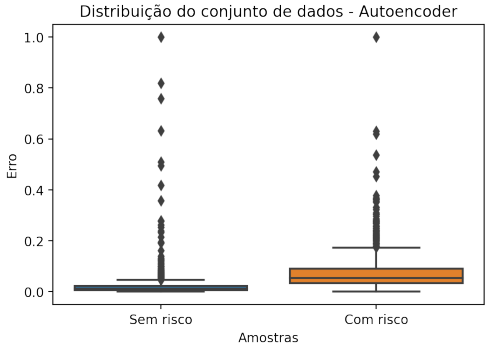

(b) Validação cruzada *k-Fold* - 2^a partição

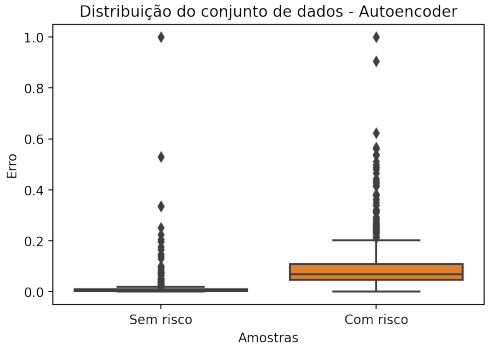

(c) Validação cruzada *k-Fold* - 5^a partição

Figura 65: Distribuição do conjunto de dados no classificador baseado em Autoencoder no modelo 3 para os diferentes métodos de validação.

3.4 Sumário Comparativo entre os Classificadores

Nesta seção, são apresentados os modelos escolhidos para cada classificadores e o comparativo através da acurácia. Para avaliação do desempenho dos classificadores é utilizada a acurácia, ou seja, percentual de amostras classificadas corretamente nas duas classes.

A Figura 66 mostra que os modelos escolhidos para treinamento dos classificadores apresentam bom desempenho de acordo com a AUC. O classificador Autoencoder apresenta maior a AUC, melhor desempenho, quando comparado a outros classificadores. Porém o classificador PCA obtém melhor desempenho em relação à acurácia nos dois métodos de validação, como mostram as Tabelas 15 e 16.

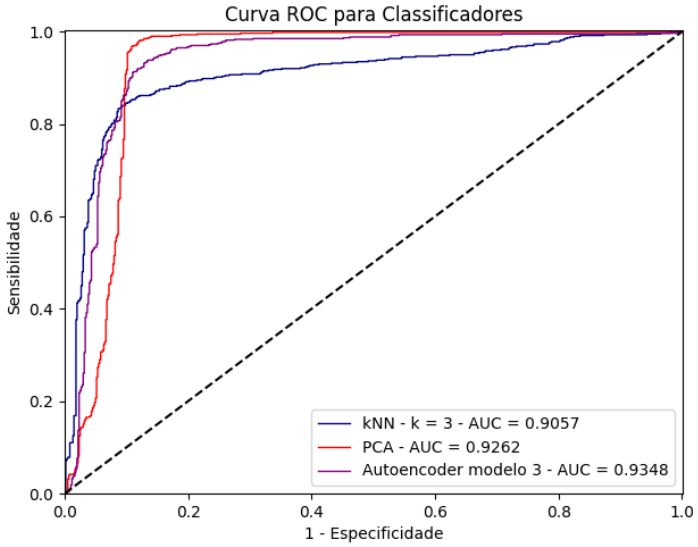

Figura 66: Curva ROC dos modelos escolhidos para treinamento dos classificadores.

Tabela 15: Acurácia (%) nos pontos de corte - Validação *Hold-out*.

	Classificadores		
Ponto de Corte	**kNN**	**PCA**	**Autoencoder**
1	86,17%	90,17%	90,00%
2	87,33%	93,00%	90,92%

Tabela 16: Acurácia média (%) nos pontos de corte - Validação cruzada *k-Fold*.

	Classificadores		
Ponto de Corte	**kNN**	**PCA**	**Autoencoder**
1	75,00%	87,29%	88,17%
2	77,18%	89,69%	89,47%

Observa-se que os três classificadores obtêm acurácias próximas nos dois pontos de corte para as diferentes abordagens de validação. Esse é um indicativos de que o sistema tem boa capacidade de identificação das amostras de cada classe.

CONCLUSÃO

Este trabalho discutiu o desenvolvimento de um sistrema de detecção de risco de queda em enfermarias/ambiente hospitalar a partir da Informação de Estado do Canal - CSI. A CSI é o estado do canal sem fio medido nas subportadoras OFDM do padrão Wi-Fi. Como a maioria dos ambientes tem acesso à rede Wi-Fi, pode-se aproveitar dessa infraestrutura.

Uma amostra de CSI na entrada do classificador pode ser "Sem risco de queda" ou "Com risco de queda". A classe "Sem risco de queda" é a classe que o classificador aprende, quando o paciente está deitado na cama na enfermaria, a classe dita normal para a enfermaria/ambiente hospitalar no turno norturno. Já a classe "Com risco de queda" indica que há pessoas em movimento no ambiente, é a condição anômala, a situação que se deseja detectar. Como é impossível obter todas as situações possíveis "Com risco de queda", emprega-se classificadores de classe única para reconhecer amostras de CSI correspondentes à situação normal na enfermaria: pouca movimentação que são típicos do horário noturno. Para construir os detectores de risco de queda emprega-se algoritmos de aprendizado de máquina.

Testou-se a abordagem acima descrita usando os algoritmos de aprendizado de máquina kNN, PCA e Autoencoder. Eles são empregados para construir classificadores distintos. Os classificadores categorizam as amostras dentre duas classes, "Sem risco de queda" e "Com risco de queda". Com o kNN, as anomalias são identificadas computando a distância média das amostras aos k padrões armazenados. Com o PCA, a detecção emprega erro de reconstrução a partir da projeção em algumas componentes principais. O detector baseado em Autoencoder também emprega o erro da reconstrução que ele produz do padrão de entrada.

A classificação depende de um limiar operacional que é empregado para separa as amostras como normais, da classe "Sem risco de queda", ou amostras anômalas da classe "Com risco de queda" a partir das distâncias acima. A escolha do ponto de corte é arbitrária, isto é, depende de decisões de projeto para a aplicação. Os classificadores foram avaliados pela capacidade de detecção de amostras CSI com anomalias. Essa abordagem não tem como objetivo determinar qual circunstância produziu a anomalia na amostra

CSI ou categorizar as anomalias, e sim visa determinar se houve anomalia ou situação de risco no ambiente.

Foram aplicados dois métodos de validação *Hold-out* e *k-Fold*. Em ambos, as amostras são separadas aleatoriamente para o treinamento e testes dos classificadores visando a obter uma melhor representação das amostras CSI, consequentemente, uma análise justa dos possíveis desempenhos dos classificadores.

A situação de "Com risco de queda" se não identificada corretamente pode ser problemática no ambiente hospitalar no horário noturno. Primeiramente, pretende-se evitar as quedas e caso ocorra uma queda ou acidente com um paciente e não haja assistência rápida. Por outro lado, situações "Sem risco de queda" que produzem falsos positivos podem acionar a equipe de enfermagem desnecessariamente. Assim, o ponto de corte dos classificadores pode ser ajustado para permitir classificadores mais liberais ou conservadores. Um classificador liberal apresenta sensibilidade maior que especificidade, desencadeando mais falsos positivos; porém, tem mais capacidade para identificar situações "Com risco de queda". Um classificador conservador apresenta sensibilidade menor que especificidade, produzindo menos falsos positivos; porém, a detecção da situação "Com risco de queda" é prejudicada.

Ao usar um classificador proposto em uma enfermaria, uma alternativa é empregar diferentes pontos de corte durante a jornada, conforme a movimentação esperada. Por exemplo, no período diurno, quando há muitos funcionários em atividade, pacientes e visitantes, pode-se empregar um ponto de corte que torna o classificador mais conservador, produzindo menos alarmes do tipo "Com risco de queda" e menos falsos positivos. No período noturno, quando há menor movimentação, o uso de um ponto de corte liberal pode ser mais adequado, produzindo mais alarmes "Com risco de queda", por ser mais sensível a mudanças no ambiente, permitindo a rápida ação da equipe de enfermagem.

Assim, avalia-se os desempenhos dos classificadores usando a curva ROC. De posse da curva ROC escolhem-se limiares operacionais, pontos de cortes para cada detector em função de suas sensibilidades e especificidades. Além da avaliação através da curva ROC (todos os pontos de corte), os classificadores foram avaliados usando pontos de corte conservadores e liberais. Esses classificadores são comparados através da acurácia: o percentual de amostras classificadas corretamente em cada classe.

Os classificadores baseados nos diferentes algoritmos de máquina foram treinados e

testados em diferentes configurações. Os resultados apresentados são dos classificadores de melhores configurações, as que obtêm os melhores desempenhos medidos através da AUC. Para o classificador kNN foi realizado treinamento com k igual à 3, 5, 7 e 9, e a configuração com k igual a 3 obteve o melhor desempenho. O classificador PCA foi testado com redução de dimensionalidade usando 3 componentes principais que representam 89,59% da energia. Já para o classificador Autoencoder foram avaliados três modelos com diferentes números de camadas e neurônios. A configuração 1 emprega sete camadas com 128-64-32-16-32-64-128 neurônios nas camadas desde a entrada até a saída. Já a configuração 2 emprega cinco camadas com topologia 128-64-32-64-128, e a 3, três camadas, com 128-64-128 neurônios. A terceira configuração obteve o melhor desempenho entre as configurações testadas.

O classificador kNN apresentou acurácia de até 87,33% na validação *Hold-out* e acurácia média de até 77,18% na validação *k-Fold*. O classificador PCA apresentou acurácia de até 93,00% na validação *Hold-out* e acurácia média de até 89,69% na validação *k-Fold* e o classificador Autoencoder obteve acurácia de até 90,92% na validação *Hold-out* e acurácia média de até 89,47% na validação *k-Fold*.

Os três classificadores apresentam bons resultados, porém o PCA e o Autoencoder, que empregam o erro de reconstrução para a detecção, apresentaram melhores desempenhos para os dois pontos de corte experimentados.

Como este trabalho foi realizado durante a Pandemia de COVID-19, não foi possível realizar a coleta de dados em enfermarias devido aos riscos intrínsecos nesses ambientes. Assim, um dos trabalhos futuros relacionados a este estudo é a coleta testes de amostras de CSI com mais voluntários e no ambiente de enfermaria, por exemplo, no Hospital Universitário Pedro Ernesto/UERJ. Outros desdobramentos são relacionados aos classificadores e suas propriedades: o emprego de outros algoritmos de aprendizado de máquina, o ajuste dos hiper-parâmetros dos modelos para seus treinamentos e o estudo de pontos de corte adequados ao ambiente da enfermaria. Pretende-se ainda implementar um sistema integrado que permita a detecção do risco de queda e efetivamente auxilie a equipe de enfermagem.

Referências Bibliográficas

[1] FANG, S.-H. et al. Enhanced device-free human detection: Efficient learning from phase and amplitude of channel state information. *IEEE Transactions on Vehicular Technology*, IEEE, v. 68, n. 3, p. 3048–3051, 2019.

[2] YANG, Z.; ZHOU, Z.; LIU, Y. From RSSI to CSI: Indoor localization via channel response. *ACM Computing Surveys (CSUR)*, ACM New York, NY, USA, v. 46, n. 2, p. 1–32, 2013.

[3] YACCHIREMA, D. et al. Fall detection system for elderly people using IoT and big data. *Procedia computer science*, Elsevier, v. 130, p. 603–610, 2018.

[4] DJAJA-JOSKO, V. Presence and fall detection in confined indoor environments using multiple UWB transceivers. In: IEEE. *2018 26th Telecommunications Forum (TELFOR)*. [S.l.], 2018. p. 1–4.

[5] MOLISCH, A. F. *Wireless communications*. [S.l.]: John Wiley & Sons, 2012.

[6] RAPPAPORT, T. S. et al. *Wireless communications: principles and practice*. [S.l.]: prentice hall PTR New Jersey, 1996.

[7] LATHI, B. P.; DING, Z. *Sistemas de comunicações analógicos e digitais modernos*. [S.l.]: LTC, Rio de Janeiro, 2012.

[8] TSE, D.; VISWANATH, P. *Fundamentals of wireless communication*. [S.l.]: Cambridge university press, 2005.

[9] XIAO, J. et al. Pilot: Passive device-free indoor localization using channel state information. In: IEEE. *2013 IEEE 33rd International Conference on Distributed Computing Systems*. [S.l.], 2013. p. 236–245.

[10] WU, K. et al. CSI-based indoor localization. *IEEE Transactions on Parallel and Distributed Systems*, IEEE, v. 24, n. 7, p. 1300–1309, 2012.

[11] SILVA, B. S. da; LAUREANO, G. T.; CARDOSO, K. V. Widmove - um sensor de movimento direcional baseado em perturbações do sinal eletromagnético de inter-

faces 802.11. In: SBC. *Anais Principais do XXXVI Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos*. [S.l.], 2018.

[12] LIU, H. et al. Practical user authentication leveraging channel state information (CSI). In: *Proceedings of the 9th ACM symposium on Information, computer and communications security*. [S.l.: s.n.], 2014. p. 389–400.

[13] OLIVEIRA, L. M. Câmeras filmadoras de monitoramento dentro e fora da unidade hospitalar. *Arquivos do CRM-PR*, v. 29, n. 115, 2012. Disponível em: <http://www.crmpr.org.br/publicacoes/cientificas/index.php/arquivos/article/download/310/300>. Acesso em: 10 de Março de 2021.

[14] SOUZA, J. A. Vedada instalação de câmeras filmadoras nas salas de atendimento em serviços de emergência. *Arquivos do CRM-PR*, v. 33, n. 130, 2016. Disponível em: <https://sistemas.cfm.org.br/normas/arquivos/pareceres/BR/2016/5_2016.pdf>. Acesso em: 10 de Março de 2021.

[15] STAUB, L. J. É vedada a instalação de câmeras de vigilância para monitoramento contínuo de pacientes em leitos de enfermaria. *Arquivos do CFM*, 2019. Disponível em: <https://sistemas.cfm.org.br/normas/visualizar/pareceres/SC/2019/58>. Acesso em: "10 de Março de 2021".

[16] CUNHA Jr et al., A. *Relatório 27 Progresso da COVID-19 no Brasil e no Estado do Rio de Janeiro 23ª à 26ª Semana Epidemiológica do Calendário 2021 (30/05/2021 até 26/06/2021)*. (2021). COVID-19: Observatório Fluminense. `https://https://doi.org/10.12957/eduerj.covid19rj.relatorio27`.

[17] WU, K. et al. FILA: Fine-grained indoor localization. In: IEEE. *2012 Proceedings IEEE INFOCOM*. [S.l.], 2012. p. 2210–2218.

[18] WANG, W. et al. Understanding and modeling of wifi signal based human activity recognition. In: *Proceedings of the 21st annual international conference on mobile computing and networking*. [S.l.: s.n.], 2015. p. 65–76.

[19] DIAS, P. V. G. et al. Fall detection monitoring system with position detection for elderly at indoor environments under supervision. In: IEEE. *2016 8th IEEE Latin-American Conference on Communications (LATINCOM)*. [S.l.], 2016. p. 1–6.

[20] YANG, J. et al. Device-free occupant activity sensing using wifi-enabled IoT devices for smart homes. *IEEE Internet of Things Journal*, IEEE, v. 5, n. 5, p. 3991–4002, 2018.

[21] BELLALTA, B. IEEE 802.11ax: High-efficiency WLANS. *IEEE Wireless Communications*, v. 23, n. 1, p. 38–46, 2016.

[22] MATYJAS, J. D.; HU, F.; KUMAR, S. *Wireless network performance enhancement via directional antennas: models, protocols, and systems*. [S.l.]: CRC Press, 2015.

[23] FLORES, A. B. et al. IEEE 802.11 af: A standard for TV white space spectrum sharing. *IEEE Communications Magazine*, IEEE, v. 51, n. 10, p. 92–100, 2013.

[24] AUST, S.; PRASAD, R. V.; NIEMEGEERS, I. G. M. M. IEEE 802.11ah: Advantages in standards and further challenges for sub 1 GHz wi-fi. In: *2012 IEEE International Conference on Communications (ICC)*. [S.l.: s.n.], 2012. p. 6885–6889.

[25] IEEE Standard for Information technology—Telecommunications and information exchange between systems Local and metropolitan area networks—Specific requirements - Part 11: Wireless LAN Medium Access Control (MAC) and Physical Layer (PHY) Specifications. *IEEE Std 802.11-2016 (Revision of IEEE Std 802.11-2012)*, p. 1–3534, 2016.

[26] MENDES, D. R. *Redes de computadores: teoria e prática*. [S.l.]: Novatec Editora, 2020.

[27] PERAHIA, E.; STACEY, R. *Next generation wireless LANs: 802.11 n and 802.11 ac*. [S.l.]: Cambridge university press, 2013.

[28] PERAHIA, E. IEEE 802.11 n development: History, process, and technology. *IEEE Communications Magazine*, IEEE, v. 46, n. 7, p. 48–55, 2008.

[29] GAST, M. S. *802.11 ac: a survival guide: Wi-Fi at gigabit and beyond*. [S.l.]: "O'Reilly Media, Inc.", 2013.

[30] PINTO, E. L.; ALBUQUERQUE, C. P. de. A técnica de transmissão OFDM. *Revista Científica*, v. 1516, p. 2338, 2002.

[31] PROAKIS, J. G.; SALEHI, M. *Fundamentals of communication systems*. [S.l.]: Pearson Education India, 2013.

[32] COSTA, R. B. F. da. *Estimação de Canal em Sistemas de Comunicação sobre Linhas de Potência*. Tese (Doutorado) — PUC-Rio, 2007.

[33] ESPRESSIF. *Wi-Fi Driver*. Disponível em: https://docs.espressif.com/projects/esp-idf/en/latest/esp32/ api-guides/wifi.html. Acesso em: 21 de março de 2021.

[34] FERREIRA, T. N.; NETTO, S. L.; DINIZ, P. S. A unitary esprit algorithm for carrier frequency offset estimation. In: IEEE. *2011 IEEE International Symposium of Circuits and Systems (ISCAS)*. [S.l.], 2011. p. 629–632.

[35] MONARD, M. C.; BARANAUSKAS, J. A. Conceitos sobre aprendizado de máquina. *Sistemas inteligentes-Fundamentos e aplicações*, Manole, v. 1, n. 1, p. 32, 2003.

[36] GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. [S.l.]: MIT Press, 2016. `http://www.deeplearningbook.org`.

[37] CASTANHEIRA, L. G. Aplicação de técnicas de mineração de dados em problemas de classificação de padrões. Universidade Federal de Minas Gerais, 2008.

[38] GOLDSCHMIDT, R.; PASSOS, E. *Data mining: um guia prático*. [S.l.]: Gulf Professional Publishing, 2005.

[39] MÜLLER, A. C.; GUIDO, S. *Introduction to machine learning with Python: a guide for data scientists*. [S.l.]: "O'Reilly Media, Inc.", 2016.

[40] PATEL, A. A. *Hands-on unsupervised learning using Python: how to build applied machine learning solutions from Unlabeled Data*. [S.l.]: O'Reilly Media, 2019.

[41] HOLLAND, S. M. Principal components analysis (PCA). *Department of Geology, University of Georgia, Athens, GA*, p. 30602–2501, 2008.

[42] BOSCHETTI, A.; MASSARON, L. *Python data science essentials*. [S.l.]: Packt Publishing Ltd, 2015.

[43] HONGYU, K.; SANDANIELO, V. L. M.; JUNIOR, G. J. de O. Análise de componentes principais: resumo teórico, aplicação e interpretação. *E&S Engineering and Science*, v. 5, n. 1, p. 83–90, 2016.

[44] SILVA, L. da; KOZAKEVICIUS, A. Análise de componentes principais: Construção via Álgebra linear. In: *Encontro Regional dos Estudantes de Matemática*. Bagé - RS: [s.n.], 2014.

[45] OLIVEIRA, J. V. d. et al. *Estudo da decomposição em valores singulares e análise dos componentes principais*. Monografia (TCC) — Universidade Federal Fluminense, Volta Redonda, 2016.

[46] SAKURADA, M.; YAIRI, T. Anomaly detection using autoencoders with nonlinear dimensionality reduction. In: *Proceedings of the MLSDA 2014 2nd Workshop on Machine Learning for Sensory Data Analysis*. [S.l.: s.n.], 2014. p. 4–11.

[47] ALLA, S.; ADARI, S. K. *Beginning anomaly detection using python-based deep learning*. [S.l.]: Springer, 2019.

[48] TENSORFLOW. *Introdução aos codificadores automáticos*. Disponível em: https://www.tensorflow.org/ tutorials/generative/autoencoder. Acesso em: 03 de abril de 2021.

[49] MENDONÇA, G. G. et al. *Redes neurais artificiais na predição do preço de ações*. Monografia (TCC) — Universidade Federal de Santa Catarina. Centro Tecnológico. Engenharia Eletrônica, Florianópolis, SC, 2019.

[50] CHOLLET, F. et al. *Deep learning with Python*. [S.l.]: Manning New York, 2018.

[51] FAWCETT, T. An introduction to ROC analysis. *Pattern recognition letters*, Elsevier, v. 27, n. 8, p. 861–874, 2006.

[52] MARTINEZ, E. Z.; LOUZADA-NETO, F.; PEREIRA, B. d. B. A curva ROC para testes diagnósticos. *Cad. saúde colet.,(Rio J.)*, p. 7–31, 2003.

[53] BRUCE, P.; BRUCE, A. *Practical statistics for data scientists: 50 essential concepts*. [S.l.]: "O'Reilly Media, Inc.", 2017.

[54] CRISTIANO, M. V. d. M. B. *Sensibilidade e especificidade na curva ROC: um caso de estudo*. Tese (Doutorado) — Escola Superior de Tecnologia e Gestão, 2017.

[55] FACELI, K. et al. Inteligência artificial: Uma abordagem de aprendizado de máquina. *Rio de Janeiro: LTC*, v. 2, p. 192, 2011.

[56] CUNHA, J. P. Z. *Um estudo comparativo das técnicas de validação cruzada aplicadas a modelos mistos*. Tese (Doutorado) — Universidade de São Paulo, 2019.

[57] LOVISOLO, L.; SOUZA, R. C. de. Improvement of objective image quality evaluation applying colour differences in the cielab colour space. *International Journal of Image Processing (IJIP)*, Citeseer, v. 5, n. 3, p. 236, 2011.

[58] BORGES, L. E. *Python para desenvolvedores: aborda Python 3.3*. [S.l.]: Novatec Editora, 2014.

[59] HARRIS, C. R. et al. Array programming with NumPy. *Nature*, Springer Science and Business Media LLC, v. 585, n. 7825, p. 357–362, set. 2020. Disponível em: <https://doi.org/10.1038/s41586-020-2649-2>.

[60] MCKINNEY, W. Data Structures for Statistical Computing in Python. In: WALT Stéfan van der; MILLMAN Jarrod (Ed.). *Proceedings of the 9th Python in Science Conference*. [S.l.: s.n.], 2010. p. 56 – 61.

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

[62] HUNTER, J. D. Matplotlib: A 2d graphics environment. *Computing in Science & Engineering*, IEEE COMPUTER SOC, v. 9, n. 3, p. 90–95, 2007.

[63] WASKOM, M. L. seaborn: statistical data visualization. *Journal of Open Source Software*, The Open Journal, v. 6, n. 60, p. 3021, 2021. Disponível em: <https://doi.org/10.21105/joss.03021>.

[64] ABADI, M. et al. *TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems*. 2015. Software available from tensorflow.org. Disponível em: <https://www.tensorflow.org/>.

[65] CHOLLET, F. et al. *Keras*. GitHub, 2015. Disponível em: <https://github.com/fchollet/keras>.

[66] SCIKIT-LEARN. *Nearest Neighbors*. Disponível em: <https://scikit-learn.org/stable/modules/neighbors.html#unsupervised-nearest-neighbors>. Acesso em: 28 de março de 2021.

[67] JOHNSON, R. A.; WICHERN, D. W. et al. *Applied multivariate statistical analysis*. [S.l.]: Prentice hall Upper Saddle River, NJ, 2002.

[68] GOLDSMITH, A. *Wireless communications*. [S.l.]: Cambridge university press, 2005.

[69] ATIF, M. et al. Wi-ESP— A tool for CSI-based device-free wi-fi sensing (DFWS). *Journal of Computational Design and Engineering*, 2020.

A ASPECTOS DE IMPLEMENTAÇÃO

A.1 IEEE 802.11

Um dos requisitos funcionais no desenvolvimento do padrão 802.11 n foi que os modos de operação deveriam ser compatíveis com as versões anteriores – 802.11*a/g*. Ainda, o grupo de desenvolvimento do padrão 802.11 n também decidiu que a interoperabilidade deveria ocorrer na camada física (PHY) [27].

Os padrões IEEE 802.11*a/g/n* empregam OFDM, em que, a Informação do Estado do Canal (CSI) fornece estimativas das amplitudes e fases da função de transferência do canal em cada subportadora.

Como descrito na Subseção 1.2.5, no cabeçalho e no preâmbulo dos padrões IEEE802.11*a, g* e *n* estão as informações da CSI.

A camada PHY consiste em duas subcamada PLCP (*Procedimento de Convergência da Camada Física*) e a subcamada PMD (*Dependente do Meio Física*).

A subcamada PMD trata das técnicas de transmissão, modulação e codificação do sinal, sendo responsável pelo envio e recebimento de pacotes no meio, enquanto a subcamada PLCP é a interface entre a camada de enlace e a camada física e o preâmbulo.

Preâmbulo 802.11*a*

O preâmbulo 802.11*a* é composto pelos seguintes campos [27], além dos campos citados na Subseção 1.2.5.

- **STF (*Shorty Training*)** - É usado para a detecção do início do pacote e configuração do controle automático de ganho (AGC). Também é utilizado para estimativa de deslocamento de frequência inicial e sincronização de tempo inicial, tem 8 μs de duração.

- **LTF (*Long Training*)** - É usado para a estimativa de canal. Além dos campos citados na Subseção 1.2.5, o LTF é uma IFFT de 64 pontos da sequência no domínio da frequência. O prefixo cíclico é composto pela segunda metade do símbolo de treinamento longo [27].

- **Signal (*SIG*)** - Contém as informações de taxa e de comprimento do pacote.

- **Data Field** - O campo Data consiste nos campos Service, *bits* de dados, *bits* finais e, se necessário, *bits* de preenchimento.

- **Service** - Os primeiros 16 *bits* do campo Dados contêm o campo Serviço. Os primeiros 7 *bits* do campo Serviço são os *bits* de inicialização do embaralhador. Eles são usados para sincronizar o decodificador e ajustados para zero assim permitir a estimativa do estado inicial do decodificador no receptor.

Preâmbulo 802.11*n*

A estrutura de pacotes de alta capacidade (HT – *High Throughput*) de formato misto é utilizado pelo padrão 802.11n para garantir compatibilidade com versões do padrão 802.11a/g.

Além dos dados já descritos na Subseção 1.2.5, o canal com largura de 20 MHz possui os seguintes campos:

Preâmbulo Legado(*Legacy Preamble*) - É a primeira parte deste preâmbulo com campos idênticos a 802.11a. Contém campos de treinamento curto não HT (L-STF), de treinamento longo não HT (L-LTF) e de sinal não HT (L-SIG), de modo que dispositivos legados podem detectar o preâmbulo. No entanto, um dispositivo 802.11n HT também precisa usar esses campos para o treinamento e a demodulação obrigatória do L-SIG.

- L-STF é usado para a detecção de início de pacote, configuração de AGC (Controle Automático de Ganho), estimativa de deslocamento de frequência e a sincronização de tempo [27].

- L-LTF é usado para gerar estimativas de canal para recebimento e para equalizar o L-SIG [27].

- L-SIG os dispositivos 802.11a / g extraem as informações de taxa, comprimento e conseguem determinar o tempo adequado para permanecer fora do ar [27].

Preâmbulo HT (*HT Preamble*) - Compreende HT-SIG, HT-STF e HT-LTF. Os dois símbolos OFDM do HTSIG, HT-SIG1 e HT-SIG2, contêm novas informações de sinalização e também são usados para a autodetecção entre pacotes MF e legados. O HT-STF é usado para refazer a configuração do AGC. Os HT-LTFs são usados para a estimativa de canal MIMO.

- HT-SIG1 e HT-SIG2 são dois símbolos, cada um contendo 24 bits de informação. Possui o campo CRC de 8 bits para a detecção de erros fortes. O *bit* CBW 20/40 é usado para indicar se a transmissão tem largura de banda de 20 MHz ou 40 MHz, que é uma informação útil para permitir que um receptor de 20 MHz determine se não é capaz de receber a transmissão, logo termine a recepção antes do tempo, reduzindo o consumo de energia.

- HT-STF permite estimativas de potência precisas para a configuração de AGC necessária para o MIMO. O HT-STF permite uma configuração de AGC mais precisa do que L-STF. [27].

Campo de dados (*Data Field*) - Muitas das etapas do processo de codificação do campo Dados são iguais às do 802.11*a*.

A.2 Sobre Sistemas OFDM

O OFDM em comunicações sem fio permite resistência a condições adversas do canal como a propagação por multipercurso que produz a Interferência Intersimbólica (ISI). Devido a ISI, múltiplas cópias do sinal chegam ao receptor com atrasos temporais que interferem no símbolo atual.

No OFDM, define-se as subportadoras de forma que a frequência de uma subportadora (máximo de seu espectro) coincidam os zeros de outras subportadoras. Além disso, é inserido um intervalo de tempo de guarda entre os símbolos sucessivos, para que não ocorra ISI. O OFDM satisfaz o Primeiro Critério de Nyquist para que ISI seja nula.

Primeiro Critério de Nyquist

Para eliminar ISI, Nyquist propôs três diferentes critérios para a formatação dos pulsos, sendo permitida a sobreposição entre eles. A formatação é realizada de modo que ocorra interferência zero em todos os outros pulsos nos instantes de tomada de decisão e permitir uma detecção correta mesmo com o espalhamento ou a sobreposição dos pulsos [7].

No Primeiro Critério de Nyquist, obtém-se ISI zero ao escolher uma forma de pulso que tenha amplitude não nula no centro ($t = 0$) e amplitudes nulas em $t = \pm nT_b$ com $n = 1, 2, 3, \ldots$, sendo T_b a separação entre pulsos sucessivos, como mostra a Figura 67.

Assim,

$$p(t) = \begin{cases} 1, & t = 0 \\ 0, & t = \pm nT_b \end{cases} \qquad T_b = \left(\frac{1}{R_b}\right), \tag{A.1}$$

a notação com o subscrito b associa um bit por pulso, mas o mesmo critério vale se um pulso comporta mais de um bit.

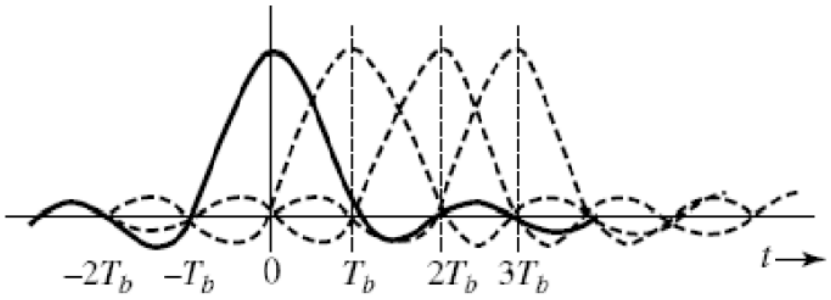

Figura 67: Pulso com mínima largura de banda que satisfaz o primeiro critério de Nyquist e o seu espectro [7].

Na Figura 67 mostra os pulsos para que satisfaçam o critério com ISI zero. Os centros de todos os pulsos consistem na amplitude de apenas um pulso (centrado no instante de amostragem), sem interferência nos demais, os pulsos tracejados em $t = 0, T_b, 2T_b$, ... [7].

Prefixo Cíclico

Como relatado na Seção 1.3, os sistemas OFDM para transmissão possuem o prefixo cíclico na transmissão e recepção com o objetivo de inserir um intervalo de guarda para eliminar a ISI entre os símbolos OFDM consecutivos.

O Prefixo Cíclico, como mostra a Figura 68, é anexado a cada bloco de N amostras do sinal $\{x_n, 0 \leq n \leq N-1\}$. No início cada bloco de amostras, o prefixo cíclico contém amostras $x_{N-m}, x_{N-m+1}, \ldots, x_{N-1}$. As últimas m amostras são anexadas ao início do bloco, formando uma sequência de amostras do sinal com comprimento $N+m$ que pode ser indexada de $-m \leq n \leq N-1$. As primeiras m amostras constituem o Prefixo Cíclico [31].

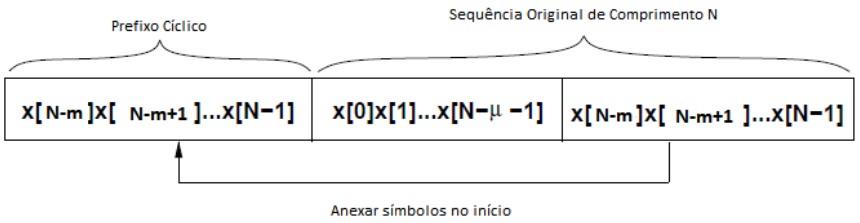

Figura 68: Prefixo Cíclico [68].

Assim, o prefixo cíclico tem como função inserir um intervalo entre os símbolos OFDM e eliminar a ISI entre eles.

A.3 Alguns Aspectos do ESP32

Para a coleta de dados CSI é utilizado o microcontrolador ESP32 conectado ao um servidor (notebook) para a coleta, armazenamento e a leitura dos dados obtidos. O módulo ESP32 pertence a uma série de microcontroladores de custo reduzido e baixo consumo de energia, projetado para aplicações IoT (*Internet-of-Things*) desenvolvido pela Espressif Systems. Esse dispositivo suporta vários protocolos como 802.11 b/g/n, Bluetooth, entre outros. Um dos objetivos deste trabalho é a utilização de um microcontrolador de baixo custo (cerca de R$40 por unidade em 2019).

Figura 69: ESP32.

A CSI consiste em Respostas de Frequência de Canal- CFR de subportadoras que são estimadas quando pacotes viajam entre o transmissor e o receptor. Cada CFR de uma subportadora é caracterizada por dois *bytes* de caracteres assinados, a primeira parte correspondente à parcela imaginária da CFR e a segunda à real.

Existem até três categorias de respostas de canal recebidos com CSI, conforme a categoria de pacote recebido, que podem ser L-LTF, HT-LTF e STBC-HT-LTF. A Figura 70 contém informações de largura, *bytes* totais e índices de subportadoras.

Canal	Canal secundário	Nenhum			Abaixo de					Acima de				
Informação do pacote	Modo de sinal	Não-HT	HT		Não-HT	HT				Não-HT	HT			
	Largura de banda do canal	20 MHz	20 MHz		20 MHz	20 MHz		40 MHz		20 MHz	20 MHz	40 MHz		
	STBC	Não STBC	Não STBC	STBC	Não STBC	Não STBC	STBC	Não STBC	STBC	Não STBC	Não STBC	STBC	Não STBC	STBC
Índice de subportadora	LLTF	0~31, −32~−1	0~31, −32~−1	0~31, −32~−1	0~63	0~63	0~63	0~63	0~63	−64~−1	−64~−1	−64~−1	−64~−1	−64~−1
	HT-LTF		0~31, −32~−1	0~31, −32~−1		0~63	0~62	0~63, −64~−1	0~60, −60~−1		−64~−1	−62~−1	0~63, −64~−1	0~60, −60~−1
	STBC- HT-LTF			0~31, −32~−1			0~62		0~60, −60~−1			−62~−1		0~63, −64~−1
Bytes totais		128	256	384	128	256	380	384	612	128	256	376	384	612

Figura 70: Informações CSI de diferentes campos de treinamento [69].

Para se obter de dados CSI, inicialmente o módulo ESP32 é configurado como uma estação que irá "escutar" o ambiente sem fio e coletar os dados CSI. O módulo é programado através da linguagem C++, conforme as especificações para nosso projeto, de modo a determinar qual canal Wi-Fi será monitorado, delimitar de quais dispositivos serão coletados a CSI e outras informações.

Um segundo módulo ESP32 é configurado para trocar informações com outros dispositivos sem fio da rede operando no padrão 802.11n. Com o tráfego de informações pela rede sem fio é possível coletar a CSI.

Para armazenar e tratar os dados CSI coletados é utilizada a linguagem de programação Python, onde é possível configurar um *script* que coleta as amostras, calcula a amplitude e a fase das subportadoras e aplica as técnicas de aprendizado de máquina para detectar anomalias no ambiente de propagação monitorado.

B AVALIAÇÃO DOS CLASSIFICADORES POR GRUPOS DE REGISTROS COM RISCO DE QUEDA

B.1 Classificador Baseado em kNN

O classificador kNN foi treinado por quatro valores de k iguais a 3, 5, 7 e 9, mas para k igual a 3 apresenta a maior AUC na maior parte das Curvas ROCs apresentadas na Figura 71.

A curva ROC é composta por 600 amostras da classe "Com risco de queda" de grupos listados na Seção 2.7 e 600 amostras "Sem risco de queda" sendo as mesmas em todos os casos analisados. Para esta metodologia de testes é aplicada apenas a validação *Hold-out* para avaliar o desempenho do classificador.

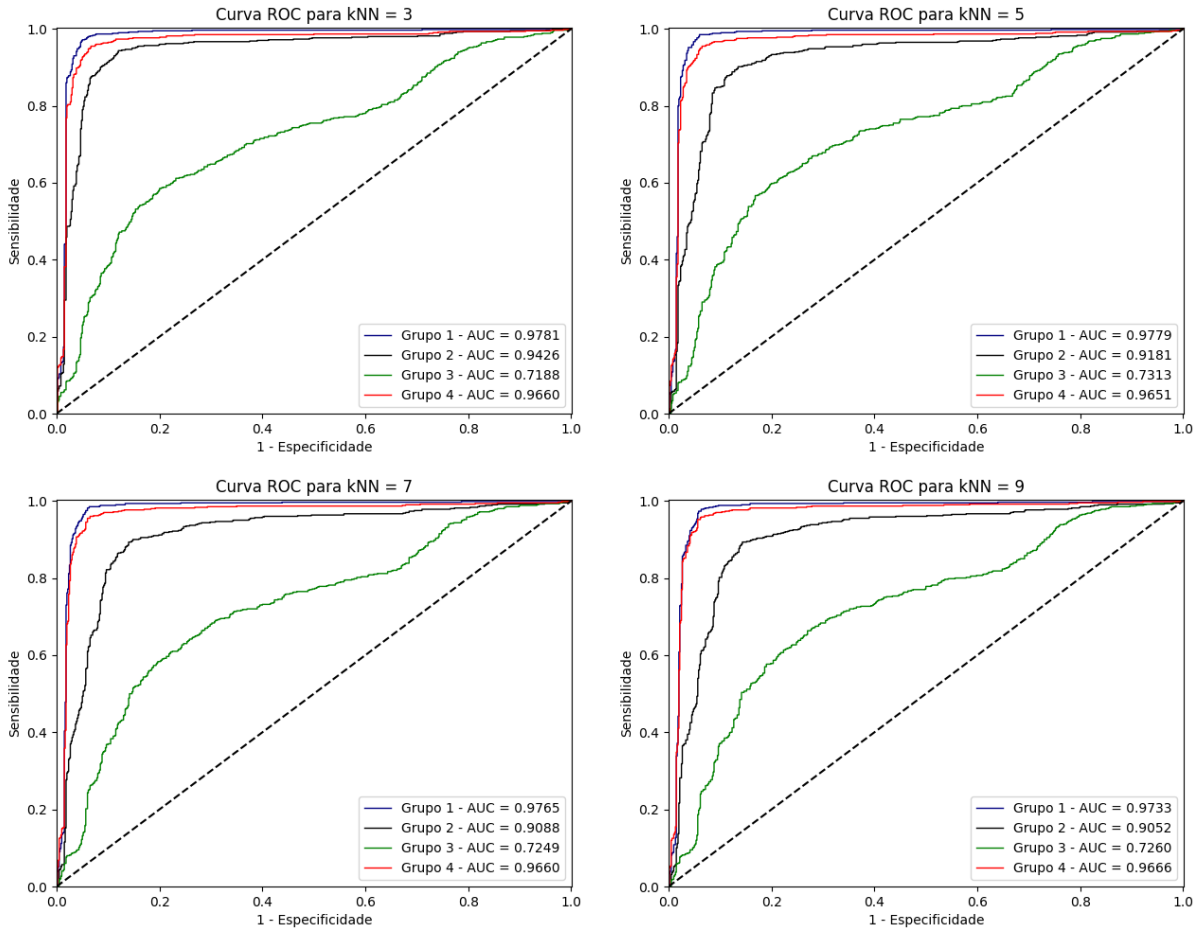

Figura 71: Curva ROC para o classificador baseado em kNN separado por grupos para diferentes valores de k - validação *Hold-out*.

- Grupo 1 – 600 amostras da classe “Com risco de queda” quando o voluntário permaneceu em movimento no ambiente de testes.

  A Figura 72 apresenta as curvas de sensibilidade, especificidade e acurácia. Observa-se que os pontos de corte tem um bom desempenho, com acurácia acima de 90%. A Figura 73 apresenta os pontos de corte na curva ROC mostrando que o ponto de corte 1 é conservador em comparação ao ponto de corte 2, com menos amostras da verdadeiro positivas e consequentemente, menos falsos positivos. Os limiares encontrados tem valores próximos. Nesta configuração possui a AUC de 0,9781, o maior valor em comparação a AUC dos grupos 2, 3 e 4.

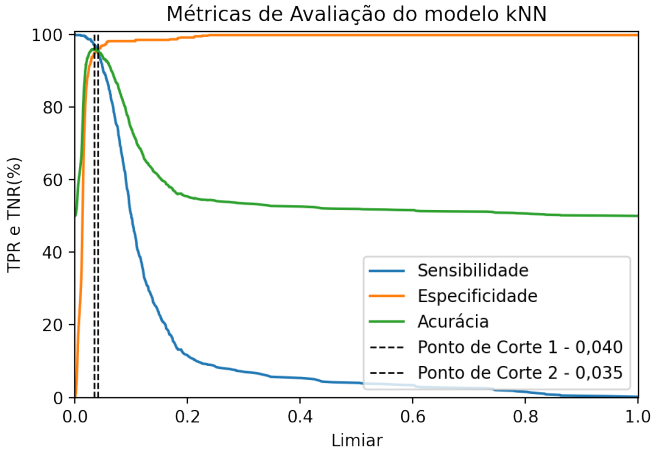

Figura 72: Localização dos pontos de corte do classificador baseado em kNN para $k = 3$ - Grupo 1 - validação *Hold-out*.

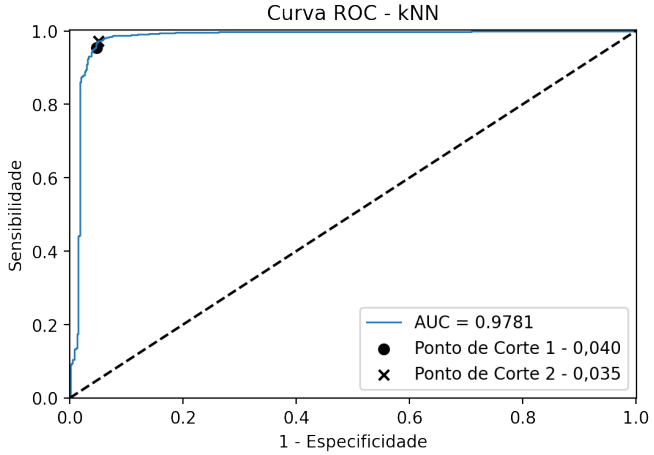

Figura 73: Localização dos pontos de corte na Curva ROC do classificador baseado em kNN para $k = 3$ - Grupo 1 - validação *Hold-out*.

A Figura 74(a) mostra que o ponto de corte 1, o classificador kNN tem capacidade de identificar a maior parte das amostras nas duas classes corretamente, 572 corretas e 28 amostras de erro. Esse ponto de corte tem sensibilidade, especificidade e acurácia de 95,33%.

O ponto de corte 2 na Figura 74(b), tem acurácia de 96,08% e maior sensibilidade que especificidade, com 97,17% e 95,00% respectivamente. Das 600 amostras da classe "Com risco de queda", o kNN previu 583 registros corretamente (verdadeiros positivos), com 30 amostras falso positivas.

A Figura 74(c) mostra que o ponto de corte 2 mais amostras de risco são detectadas corretamente (verdadeiros positivos) e com pequena diferença nos erros (falsos positivos) detectados nos dois pontos de corte.

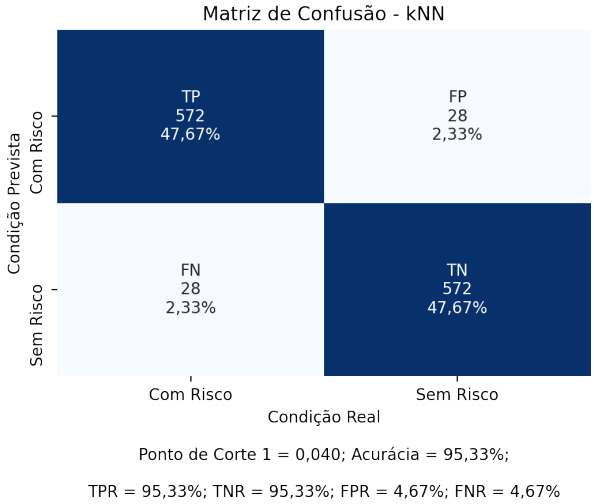

(a) Ponto de Corte 1

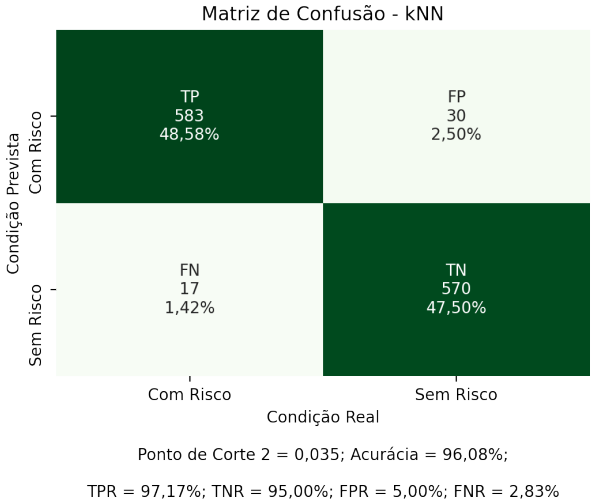

(b) Ponto de Corte 2

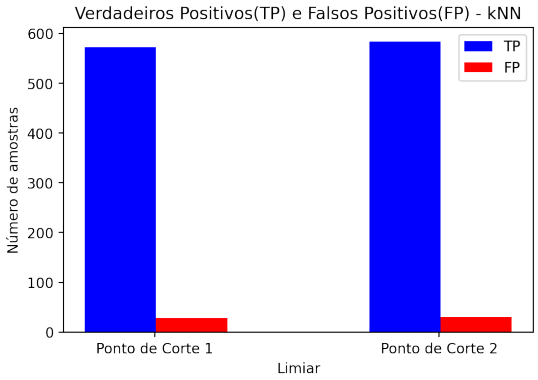

(c) Amostras previstas na classe "Com risco de queda" no Grupo 1.

Figura 74: Matriz de Confusão e amostras TP e FP dos pontos de corte no classificador baseado em kNN para $k = 3$ - Grupo 1 - validação *Hold-out*.

- Grupo 2 – 600 amostras da classe “Com risco de queda” quando o voluntário permaneceu em pé próximo à cama do ambiente de testes.

  A Figura 75 apresenta as curvas de sensibilidade, especificidade e acurácia. Esta configuração possui AUC de 0,9426 e produz acurácia acima de 90,00%. Na Figura 76 mostra o posicionamento dos pontos de corte na curva ROC e indica que o ponto de corte 1 é mais conservador que o ponto de corte 2.

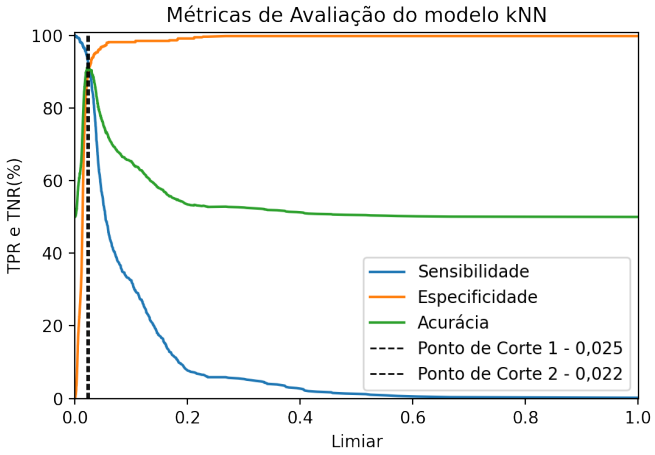

Figura 75: Localização dos pontos de corte do classificador baseado em kNN para $k = 3$ - Grupo 2 - validação *Hold-out*.

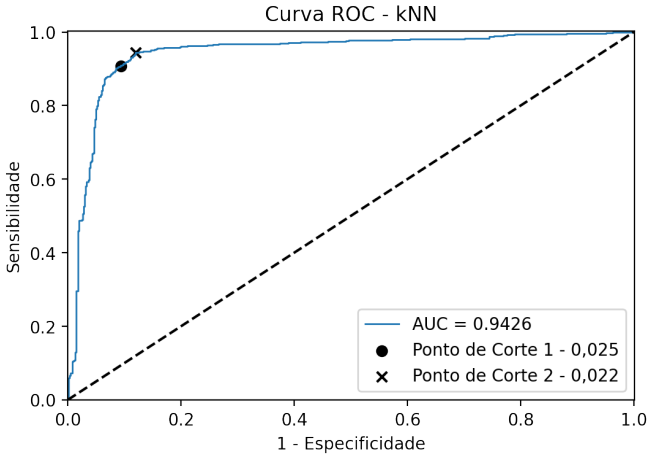

Figura 76: Localização dos pontos de corte na Curva ROC do classificador baseado em kNN para $k = 3$ - Grupo 2 - validação *Hold-out*.

A Figura 77(a) mostra que o ponto de corte 1 apresenta acurácia, especificidade e sensibilidade de 90,67%, com 544 acertos e 56 erros em cada classe.

A Figura 77(b) mostra que o ponto de corte 2 produz sensibilidade de 94,33%,

especificidade de 88,00% e acurácia de 91,17%. Este ponto de corte apresenta mais amostras da classe de risco de quedas previstas corretamente que o ponto de corte anterior, são 566 registros verdadeiros positivos, porém são detectadas 72 amostras falso positivas.

Na Figura 77(c) mostra a diferença nos dois pontos de corte das amostras previstas da classe "Com risco de queda".

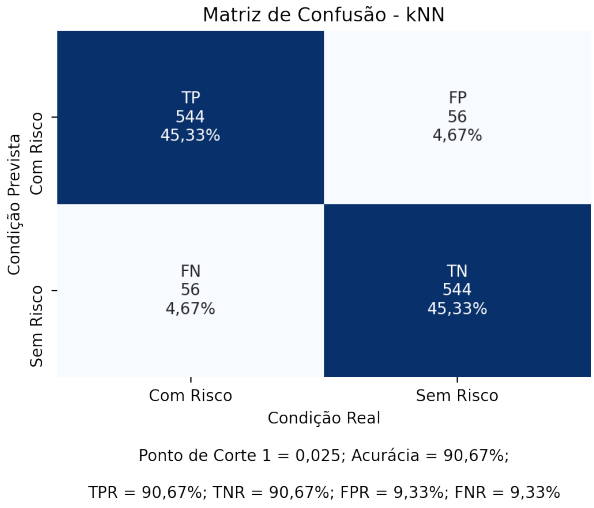

(a) Ponto de Corte 1

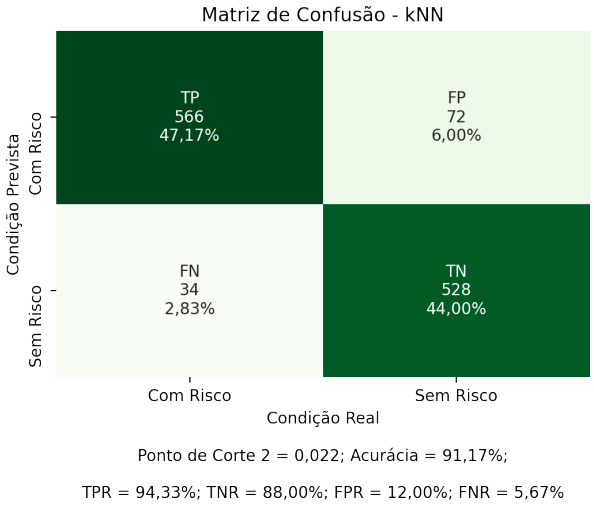

(b) Ponto de Corte 2

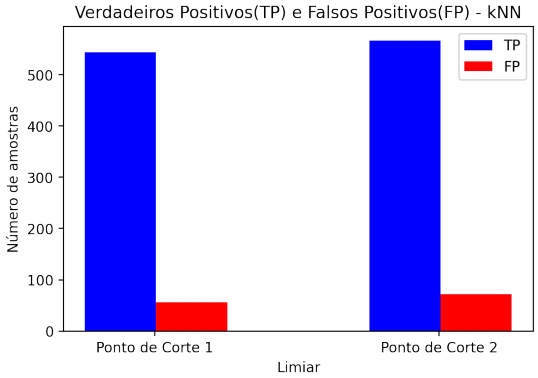

(c) Amostras previstas na classe "Com risco de queda" no Grupo 2.

Figura 77: Matriz de Confusão e amostras TP e FP dos pontos de corte no classificador baseado em kNN para $k = 3$ - Grupo 2 - validação *Hold-out*.

- Grupo 3 – 600 amostras da classe “Com risco de queda” quando o voluntário simulou queda no ambiente de testes.

  Neste Grupo menos amostras de risco são previstas quando comparado aos outros grupos com amostras CSI. A Figura 78 apresenta as curvas de sensibilidade, especificidade e acurácia menor que 70,00%. A Figura 79 mostra o ponto de corte 2 mais conservador que o ponto de corte 1 e esta configuração possui AUC de 0,7188, sendo a menor dos grupos com amostras da classe “Com risco de queda”.

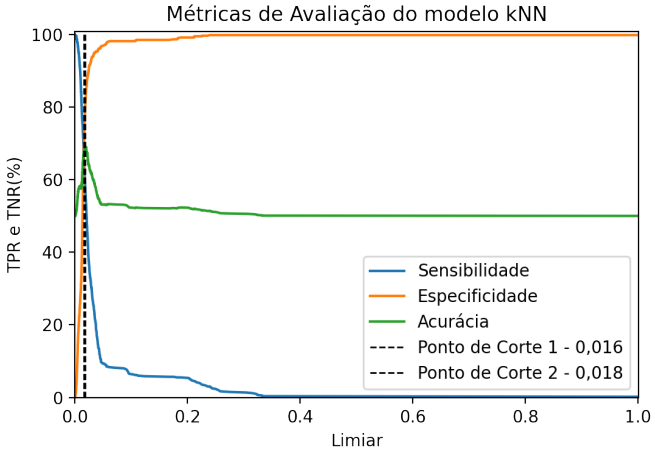

Figura 78: Localização dos pontos de corte do classificador baseado em kNN para $k = 3$ - Grupo 3 - validação *Hold-out*.

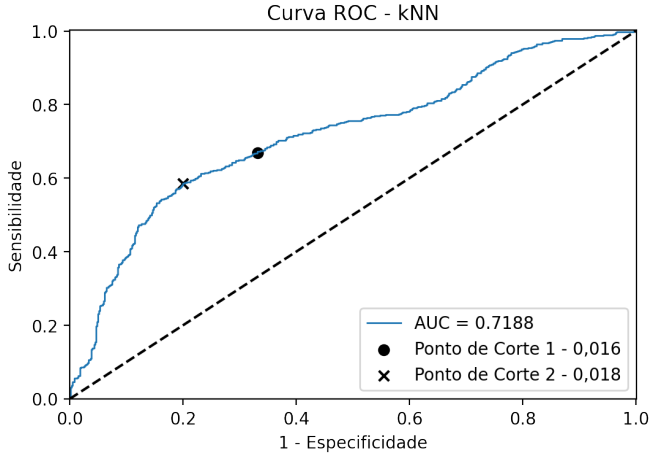

Figura 79: Localização dos pontos de corte na Curva ROC do classificador baseado em kNN para $k = 3$ - Grupo 3 - validação *Hold-out*.

A Figura 80(a) mostra o ponto de corte 1 com acurácia, especificidade e sensibilidade de 66,83%, com 401 acertos e 199 erros em cada classe.

O ponto de corte 2 apresentado na Figura 80(b) tem menos amostras previstas corretamente, são 351 registros verdadeiros positivos e 120 amostras falso positivas. Neste ponto de corte tem sensibilidade de 58,50%, especificidade de 80% e acurácia de 69,25%. Como o ponto de corte 2 apresenta especificidade maior que sensibilidade, mais amostras da classe "Sem risco de queda" são previstas corretamente quando comparado a quantidade de amostras da classe "Com risco de queda".

A Figura 80(c) mostra a diferença das amostras previstas da classe "Com risco de queda". O ponto de corte 1 é mais flexível que o ponto de corte 2, portanto são apresentadas mais amostras verdadeiro positivas e consequentemente mais falsos positivos.

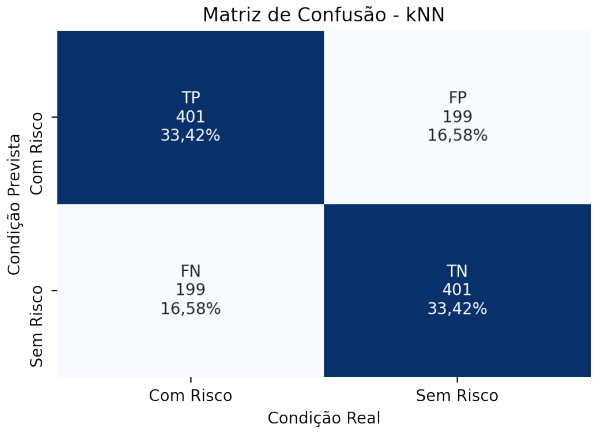

(a) Ponto de Corte 1

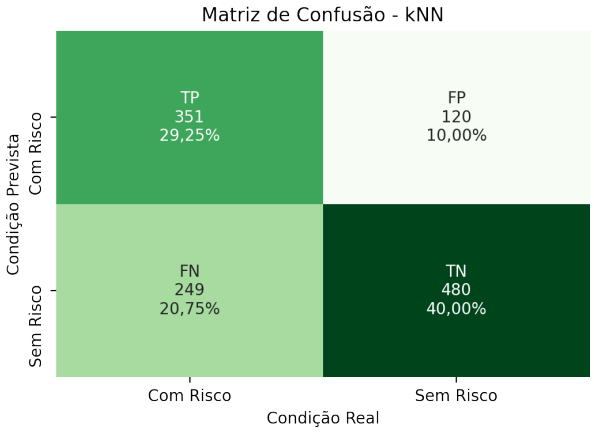

(b) Ponto de Corte 2

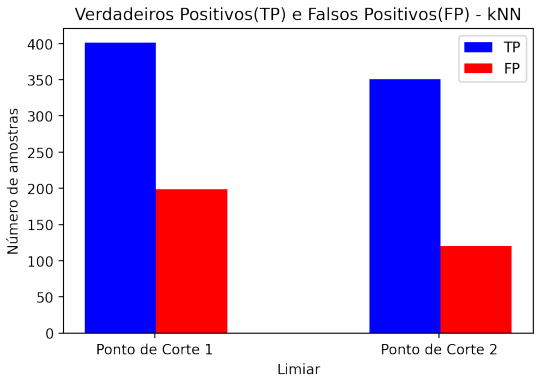

(c) Amostras previstas na classe "Com risco de queda" no Grupo 3.

Figura 80: Matriz de Confusão e amostras TP e FP dos pontos de corte no classificador baseado em kNN para $k = 3$ - Grupo 3 - validação *Hold-out*.

- Grupo 4 – 600 amostras da classe “Com risco de queda” quando o voluntário permaneceu sentado em uma cadeira, com a distância de 1 metro da cama disponível no ambiente de testes.

  O Grupo apresenta desempenho semelhante ao Grupo 1. A Figura 81 mostra os pontos de corte com acurácia de aproximadamente 90,00% e a Figura 82 os pontos de corte estão com valores próximos, mas o ponto de corte 1 é conservador quando comparado ao ponto de corte 2. Esta configuração possui AUC de 0,9660.

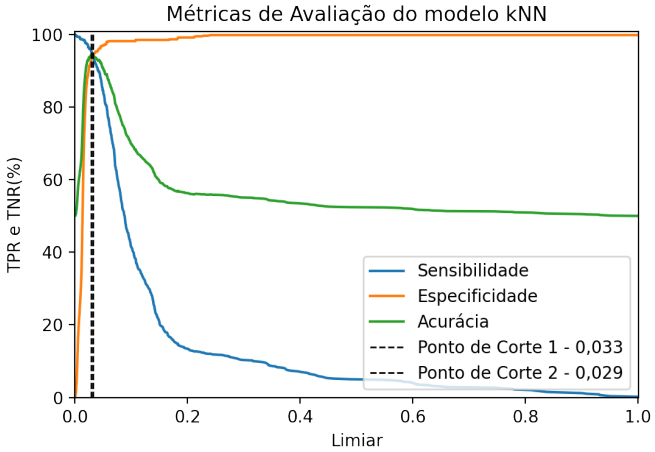

Figura 81: Localização dos pontos de corte do classificador baseado em kNN para $k = 3$ - Grupo 4 - validação *Hold-out*.

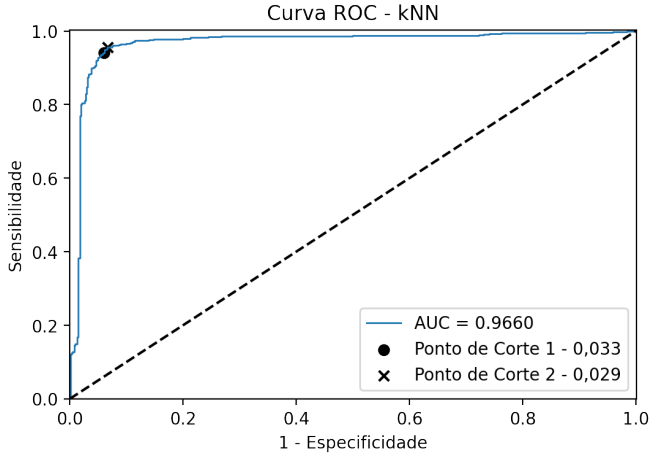

Figura 82: Localização dos pontos de corte na Curva ROC do classificador baseado em kNN para $k = 3$ - Grupo 4 - validação *Hold-out*.

A Figura 83(a) mostra o ponto de corte 1 com acurácia, especificidade e sensibilidade de 94,00%, com 564 acertos e 36 amostras com erros por classe.

O ponto de corte 2 Figura 83(b) tem sensibilidade de 95,50%, especificidade de 93,33%, acurácia de 94,42% e apresenta mais amostras previstas corretamente, são 573 registros verdadeiros positivos e 40 amostras falso positivas.

Em comparação, o ponto de corte 2 consegue prever mais amostras de risco corretamente que o ponto de corte 1, com pequena diferença em relação aos erros.

A Figura 83(c) mostra os dois pontos de corte com as amostras previstas da classe "Com risco de queda". O ponto de corte 2 apresenta mais acertos e pequena diferença em relação aos erros.

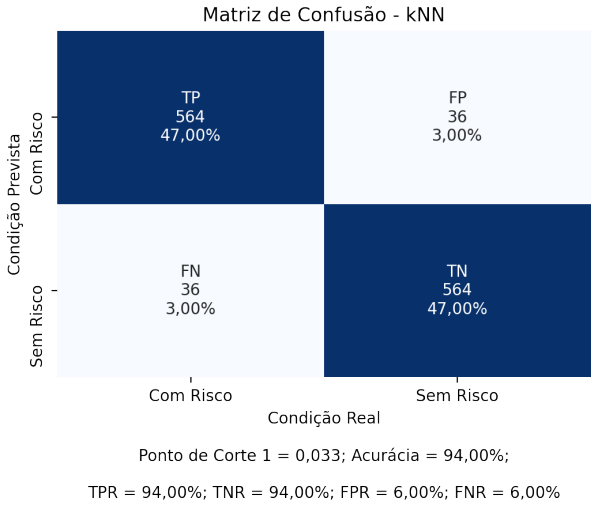

(a) Ponto de Corte 1

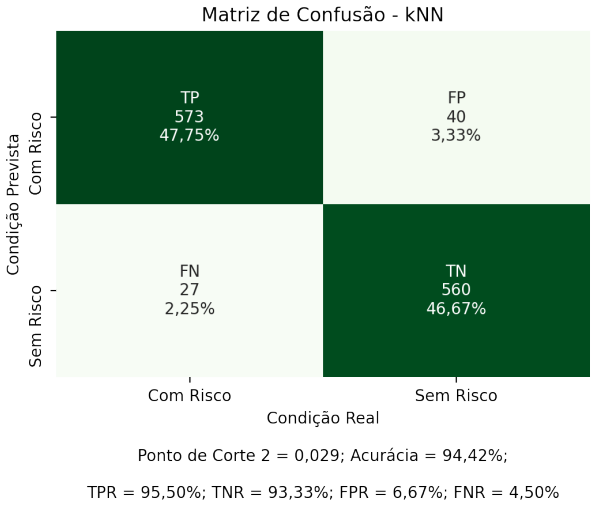

(b) Ponto de Corte 2

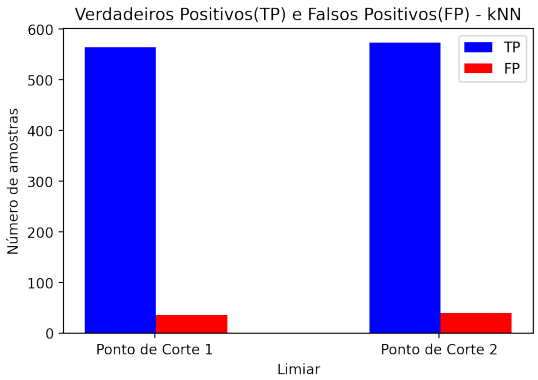

(c) Amostras previstas na classe "Com risco de queda" no Grupo 4.

Figura 83: Matriz de Confusão e amostras TP e FP dos pontos de corte no classificador baseado em kNN para $k = 3$ - Grupo 4 - validação *Hold-out*.

B.1.1 Análise dos Resultados do Classificador kNN

O desempenho dos grupos com amostras de risco de queda é medido a partir da acurácia, sendo o percentual de amostras classificadas corretamente pela quantidade total de amostras a serem classificadas. Como o desempenho do classificador é avaliado usando classes balanceadas, podemos avaliar a acurácia, sem favorecer nenhuma classe.

A Tabela 17 mostra a acurácia do classificador frente os diferentes grupos para os dois pontos de corte estabelecidos na Seção 2.4.

Tabela 17: Acurácia para os diferentes grupos no Classificador baseado em kNN para k = 3 - validação *Hold-out*.

Grupos	**Acurácia**	
	Ponto de Corte 1	**Ponto de Corte 2**
Grupo 1	95,33%	96,08%
Grupo 2	90,67%	91,17%
Grupo 3	66,83%	69,25%
Grupo 4	94,00%	94,42%

A Tabela 17 mostra que o classificador kNN quando treinado para k igual a 3, apresenta bons desempenhos para os diferentes grupos nos dois pontos de corte. O ponto de corte 2 alcança melhor acurácia em todos os casos, exceto para quedas do Grupo 3 (composto por simulações de queda pelo voluntário no ambiente de testes). Como veremos nas seções posteriores, dentre os três classificadores (kNN, PCA e Autoencoder), apesar dos bons valores de acurácia na Tabela 17, o kNN apresenta o menor percentual de acertos, isto é, o pior desempenho.

A Figura 84 apresenta a distribuição dos valores de distância média "Sem risco de queda" e de cada Grupo com amostras "Com risco de queda" .

Para os registros "Sem risco de queda" observa-se menores valores da distância média e sua distribuição está mais concentrada e menos dispersa em comparação aos grupos com amostras "Com risco de queda". Por apresentar menor dispersão das amostras "Sem risco de queda", esses registros tem menos *outliers* que os grupos com risco de queda.

Nota-se que a distância média do classificador kNN para amostras "Sem risco de queda" por apresentar menores valores de distância média, possui poucas amostras com valores discrepantes que possam representar amostras de CSI com anormalidades.

Diferente dos grupos que tenham amostras “Com risco de queda”, com muitos *outliers* e valores indicando anormalidades na amostras de CSI.

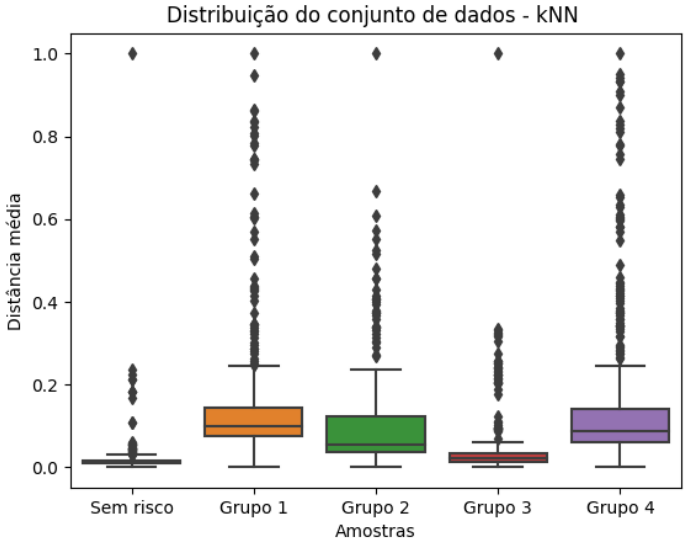

Figura 84: Distribuição do conjunto de dados para o classificador baseado em kNN para $k = 3$ - validação *Hold-out*.

B.2 Classificador Baseado em PCA

Com o classificador baseado em PCA foi realizada a redução de dimensionalidade de 128 variáveis para 3 componentes principais (CPs). Em seguida, é comparado o erro de reconstrução (MSE) entre as amostras de risco dos Grupos descritos na Seção 2.7 e 20% das amostras "Sem risco de queda", sendo as mesmas em todos os casos analisados. É aplicado o método de validação *Hold-out* para treino e testes do classificador.

A Figura 85 mostra a Curva ROC e AUC entre as amostras de risco de cada grupo e as amostras "Sem risco de queda".

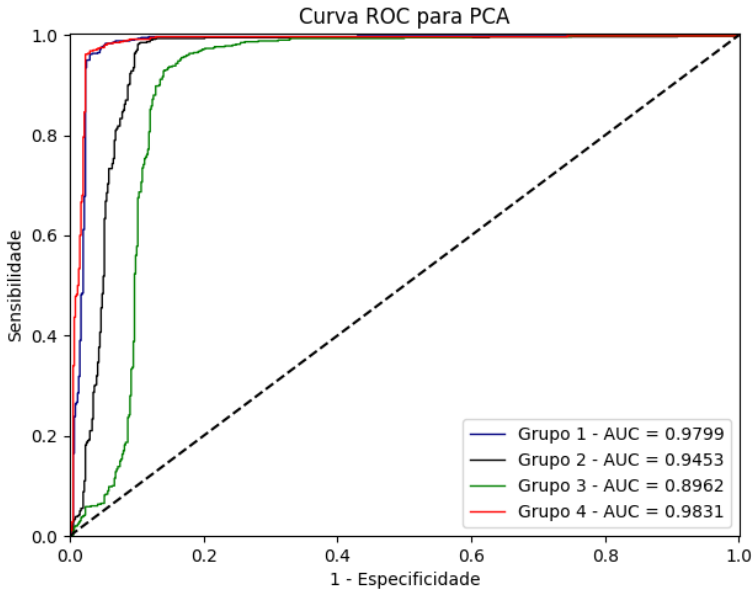

Figura 85: Curva ROC do classificador baseado em PCA com 3 CPs por Grupos - validação *Hold-out*.

- **Grupo 1**

  A Figura 86 mostra os pontos de corte e as curvas de sensibilidade, especificidade e acurácia e na Figura 87 mostra a localização dos pontos de corte na Curva ROC, onde o ponto de corte 2 é conservador em relação ao ponto de corte 1, mas apresentam valores próximos e AUC de 0,9799.

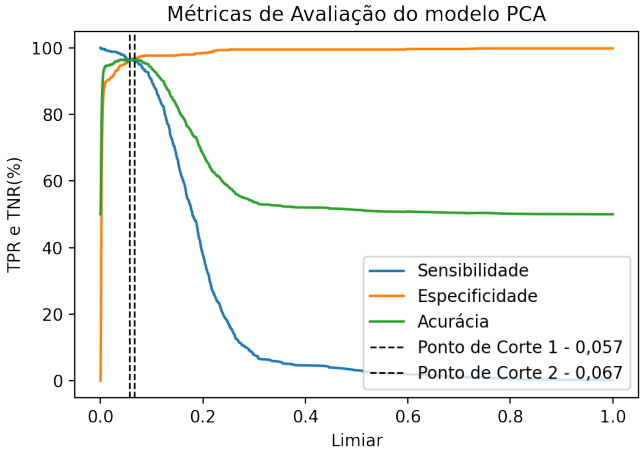

Figura 86: Localização dos pontos de corte do classificador baseado em PCA com 3 CPs - Grupo 1 - validação *Hold-out*.

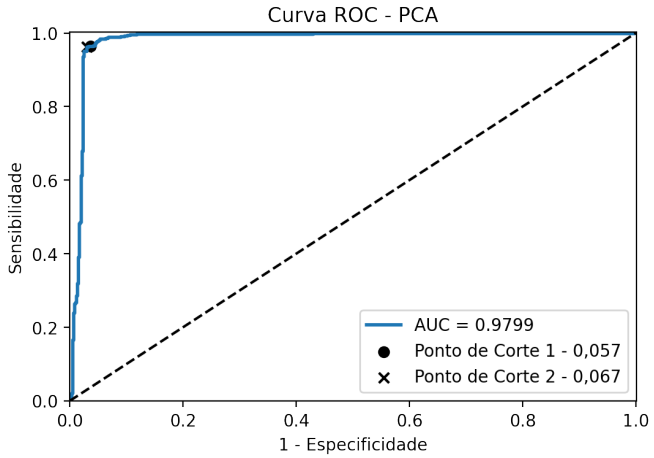

Figura 87: Localização dos pontos de corte na Curva ROC do classificador baseado em PCA com 3 CPs - Grupo 1 - validação *Hold-out*.

A matriz de confusão do ponto de corte 1 é apresentada na Figura 88(a) com sensibilidade, especificidade e acurácia de 96,33%. Neste ponto de corte são obtidas 578 registros com acertos e 22 com erros em cada classe. A Figura 88(b) apresenta a matriz de confusão no ponto de corte 2, com desempenho similar ao ponto de corte 1, com sensibilidade de 96,17%, especificidade de 97% e acurácia de 96,58%. Das amostras previstas na classe "Com risco de queda" tem 577 registros previstos corretamente (amostras verdadeiro positivas) e 18 com erros (amostras falso positivas).

A Figura 88(c) mostra a quantidade de amostras previstas na classe "Com risco de queda", e observa-se que os pontos de corte tem desempenho semelhante, com a maior parte das amostras dessa classe.

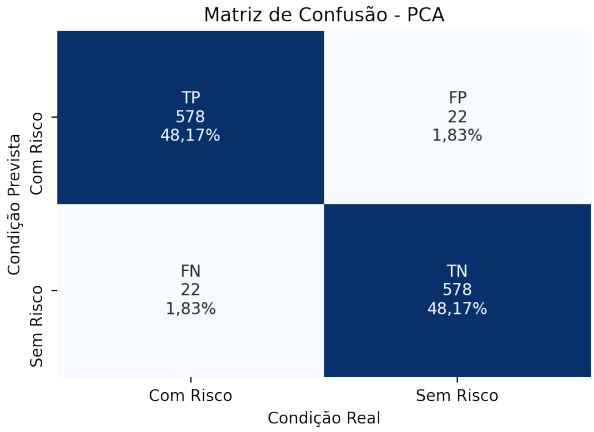

(a) Ponto de Corte 1

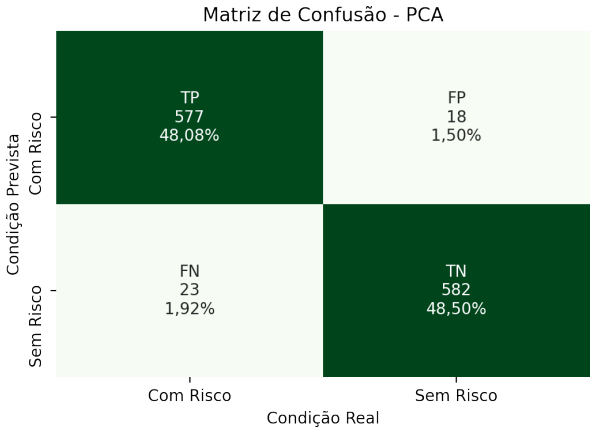

(b) Ponto de Corte 2

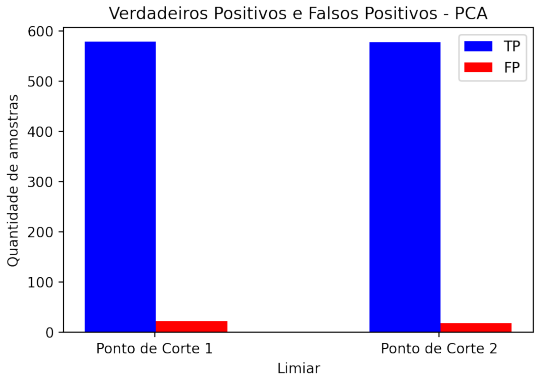

(c) Amostras previstas na classe "Com risco de queda" no Grupo 1.

Figura 88: Matriz de Confusão e amostras TP e FP dos pontos de corte no classificador baseado em PCA com 3 CPs - Grupo 1 - validação *Hold-out*.

- **Grupo 2**

  A Figura 89 mostra as curvas de sensibilidade, especificidade e acurácia. A Figura 90 localização dos pontos de corte na Curva ROC, com o ponto de corte 1 é mais conservador que o ponto de corte 2. Este grupo apresenta AUC de 0,9453.

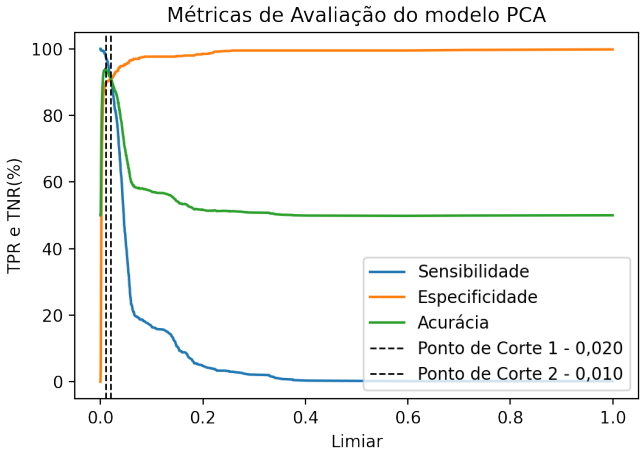

Figura 89: Localização dos pontos de corte do classificador baseado em PCA com 3 CPs - Grupo 2 - validação *Hold-out*.

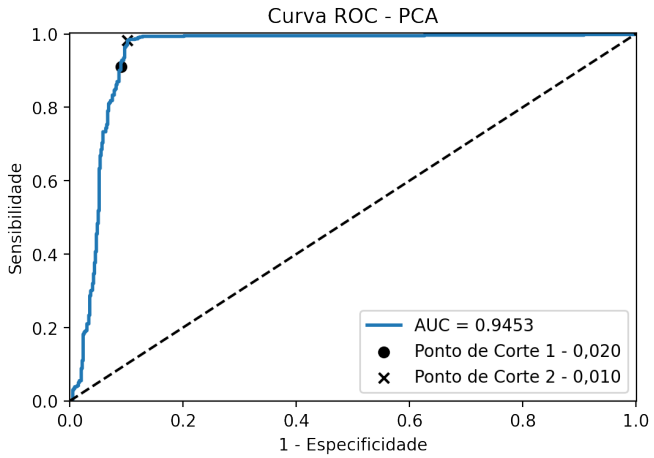

Figura 90: Localização dos pontos de corte na Curva ROC do classificador baseado em PCA com 3 CPs - Grupo 2 - validação *Hold-out*.

A Figura 91(a) mostra a matriz de confusão do ponto de corte 1 com sensibilidade, especificidade e acurácia de 91%, com 546 amostras corretas e 54 erros em cada classe.

A matriz de confusão do ponto de corte 2 apresentada na Figura 91(b) mostra que nas amostras previstas da classe “Com risco de queda” possui sensibilidade de

98,17%, especificidade de 89,83% e acurácia de 94,00%, com 589 amostras verdadeiro positivas e 61 falsos positivos.

A Figura 91(c) mostra as amostras verdadeiros positivas e falso positivas, ou seja, os registros previstos como amostras da classe "Com risco de queda". O ponto de corte 1 por ser conservador quando comparado ao ponto de corte 2, apresenta menos amostras previstas corretamente, mas em relação aos erros, o ponto de corte 1 produz 54 amostras falso positivas e no ponto de corte 2 são 61 amostras. A diferença é pequena, o que pode compensar o uso de um ponto de corte mais flexível, pois no ponto de corte 1 são previstas corretamente 546 amostras e no ponto de corte 2 são 589 amostras.

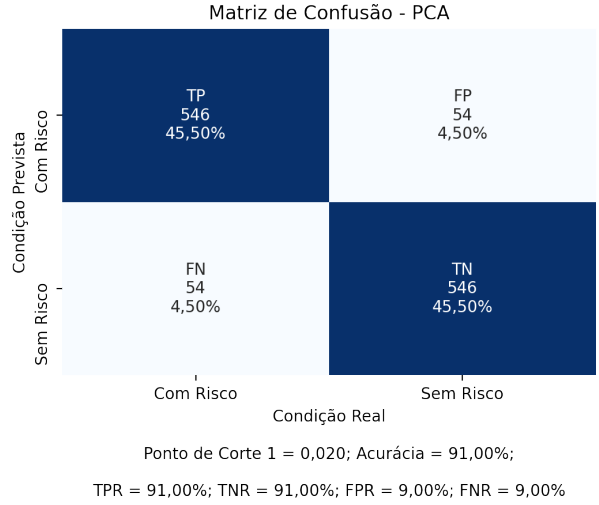

(a) Ponto de Corte 1

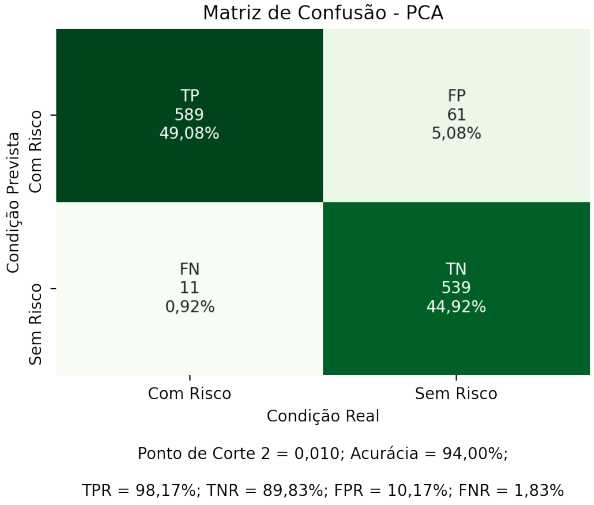

(b) Ponto de Corte 2

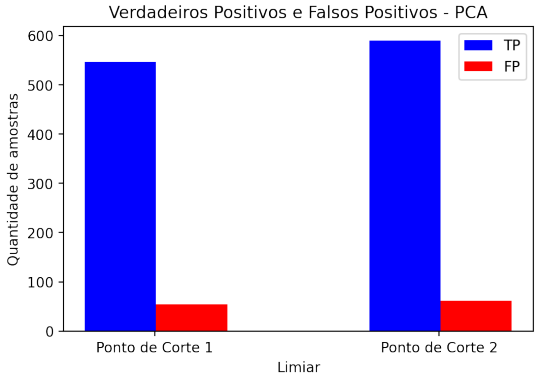

(c) Amostras previstas na classe "Com risco de queda" no Grupo 2.

Figura 91: Matriz de Confusão e amostras TP e FP dos pontos de corte no classificador baseado em PCA com 3 CPs - Grupo 2 - validação *Hold-out*.

- **Grupo 3**

  A Figura 92 mostra as curvas de sensibilidade, especificidade e acurácia acima 85% nos pontos de corte. A curva ROC é apresentada na Figura 93 mostra o posicionamento dos pontos de corte, com o ponto de corte 1 conservador comparado ao ponto de corte 2. Este grupo apresenta menor AUC (0,8962) quando comparado aos outros grupos com amostras de risco de queda.

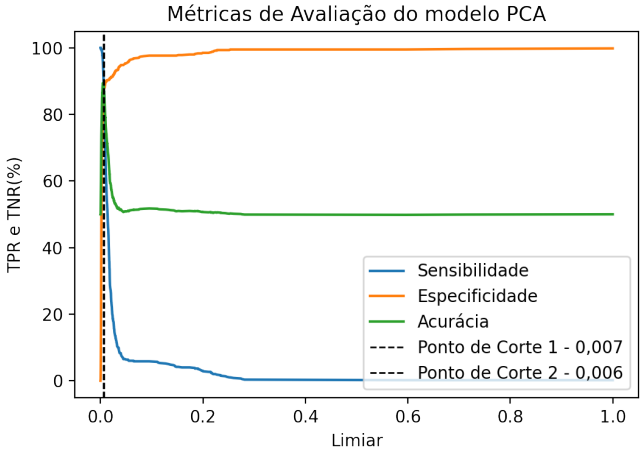

Figura 92: Localização dos pontos de corte do classificador baseado em PCA com 3 CPs - Grupo 3 - validação *Hold-out*.

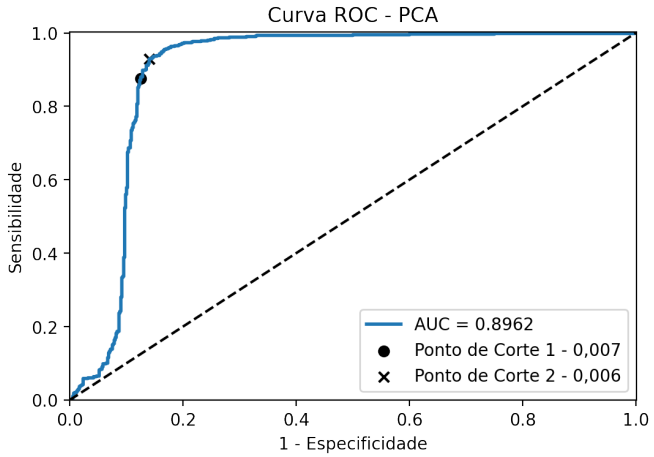

Figura 93: Localização dos pontos de corte na Curva ROC do classificador baseado em PCA com 3 CPs - Grupo 3 - validação *Hold-out*.

As matrizes de confusão dos pontos de corte são apresentas na Figura 94(a) e (b). O ponto de corte 1 tem sensibilidade, especificidade e acurácia de 87,50%, com 525 amostras corretas e 75 erros em cada classe.

O ponto de corte 2 possui sensibilidade de 92,83%, especificidade de 86% e acurácia de 89,42%. Por ser um ponto de corte mais flexível que o ponto de corte anterior, mais amostras "Com risco de queda" são previstas corretamente, porém apresenta mais falsos positivos. São 557 amostras verdadeiro positivas e 84 amostras falso positivas.

A Figura 94(c) ilustra as amostras previstas da classe "Com risco de queda". O ponto de corte 2 apresenta mais acertos que o ponto de corte 1, e como esperado, mais amostras falso positivas que o ponto de corte 1. Em relação aos acertos e erros, o ponto de corte 2 apresenta 32 amostras acertos e 9 com erros a mais que o ponto de corte 1. Em algumas condições a escolha por um ponto de corte menos conservador pode compensar, para detecção de mais amostras de risco.

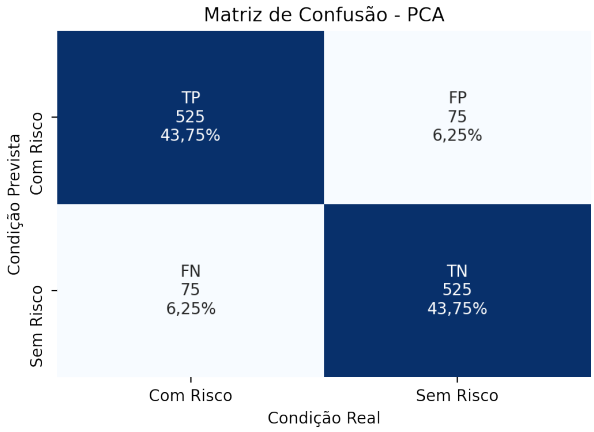

Ponto de Corte 1 = 0,007; Acurácia = 87,50%;

TPR = 87,50%; TNR = 87,50%; FPR = 12,50%; FNR = 12,50%

(a) Ponto de Corte 1

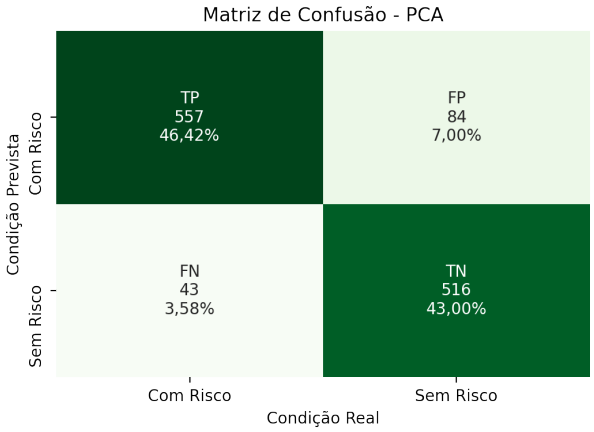

Ponto de Corte 2 = 0,006; Acurácia = 89,42%;

TPR = 92,83%; TNR = 86,00%; FPR = 14,00%; FNR = 7,17%

(b) Ponto de Corte 2

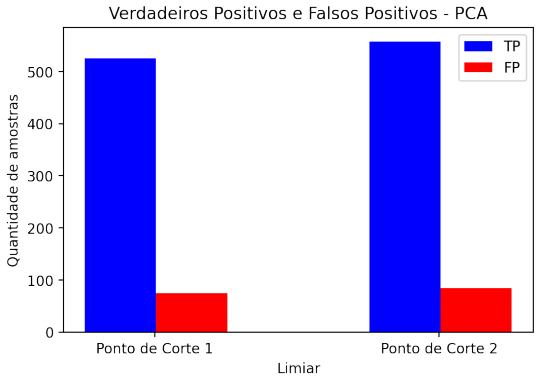

(c) Amostras previstas na classe "Com risco de queda" no Grupo 3.

Figura 94: Matriz de Confusão e amostras TP e FP dos pontos de corte no classificador baseado em PCA com 3 CPs - Grupo 3 - validação *Hold-out*.

- **Grupo 4**

  A Figura 95 apresenta as curvas de sensibilidade, especificidade e acurácia e a Figura 96 mostra a localização dos pontos de corte na Curva ROC, com o ponto de corte 2 conservador em relação ao ponto de corte 1 e AUC de 0,9831.

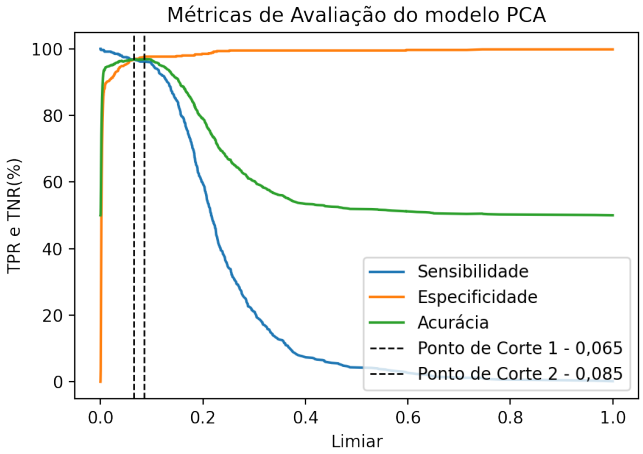

Figura 95: Localização dos pontos de corte do classificador baseado em PCA com 3 CPs - Grupo 4 - validação *Hold-out*.

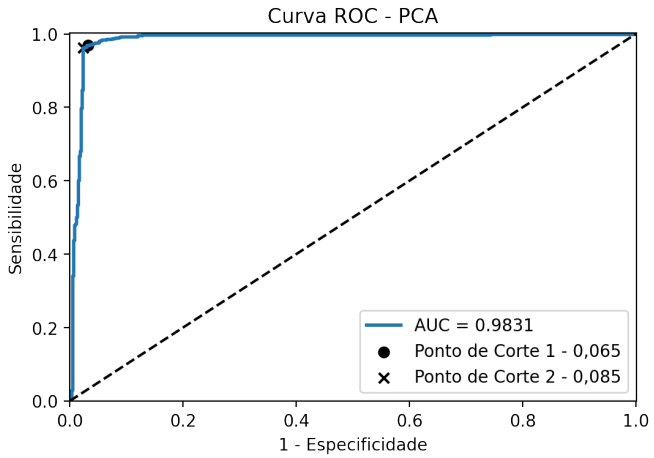

Figura 96: Localização dos pontos de corte na Curva ROC do classificador baseado em PCA com 3 CPs - Grupo 4 - validação *Hold-out*.

A Figura 97(a) mostra a matriz de confusão do ponto de corte 1 com sensibilidade, especificidade e acurácia de 96,83%, com 581 amostras corretas e 19 erros em cada classe.

O ponto de corte 2 da Figura 97(b) mostra que nas amostras previstas da classe "Com risco de queda", por ser mais conservador que o ponto de corte anterior,

possui sensibilidade de 96,17%, especificidade de 97,67% e acurácia de 96,92%, com 577 amostras verdadeiro positivas e 14 falsos positivos.

A Figura 97(c) mostra as amostras verdadeiros positivas e falso positivas. O ponto de corte 1 apresenta mais amostras previstas corretamente, e consequentemente mais falsos positivos, que o ponto de corte 2. Porém os valores apresentados nos dois pontos de corte são bem próximos com poucas diferenças entre erros e acertos.

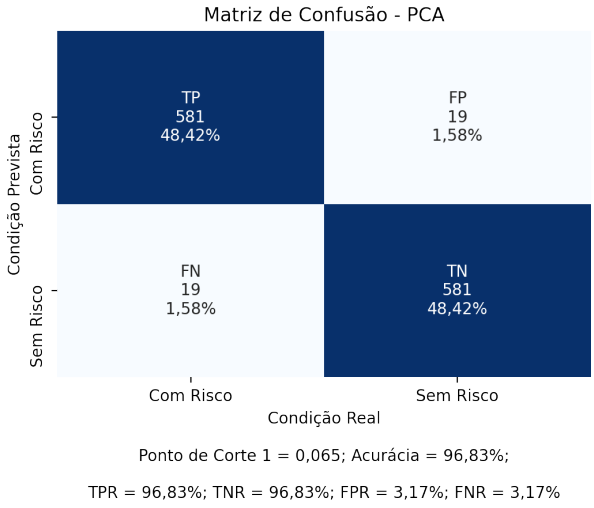

(a) Ponto de Corte 1

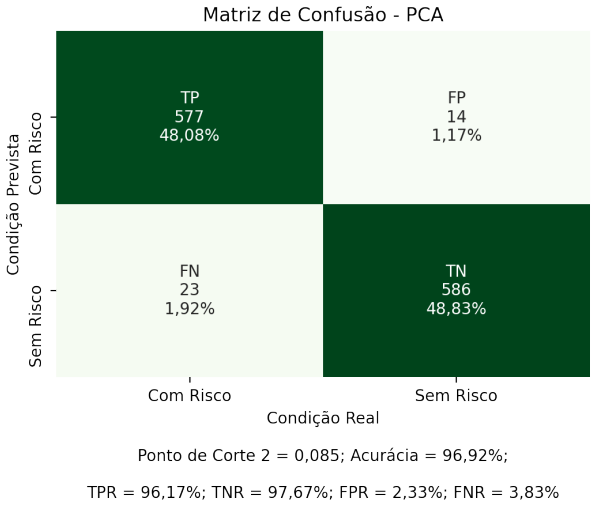

(b) Ponto de Corte 2

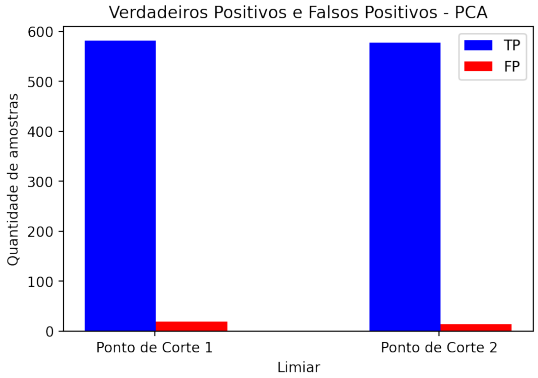

(c) Amostras previstas na classe "Com risco de queda" no Grupo 4.

Figura 97: Matriz de Confusão e amostras TP e FP dos pontos de corte no classificador baseado em PCA com 3 CPs - Grupo 4 - validação *Hold-out*.

B.2.1 Análise dos Resultados do Classificador PCA

Tabela 18: Acurácia para os diferentes grupos no Classificador baseado em PCA com 3 CPs - validação *Hold-out*.

Grupos	**Acurácia**	
	Ponto de Corte 1	**Ponto de Corte 2**
Grupo 1	96,17%	96,58%
Grupo 2	91,00%	94,00%
Grupo 3	87,50%	89,42%
Grupo 4	96,83%	96,92%

A Tabela 18 apresenta a acurácia obtida nos grupos com amostras "Com risco de queda". Todos os grupos tem bom desempenho nos pontos de corte, com acurácia acima de 87,50%. O ponto de corte 2 apresenta melhor resultado em todos os grupos, com acurácia de até 96,58%. O Grupo 3 com amostras de CSI quando simulada queda pelo voluntário, como ocorre com o classificador kNN, produz a menor acurácia nos grupos de amostras "Com risco de queda". Quando comparado com o kNN e o Autoencoder, nota-se que classificador baseado em PCA tem melhor desempenho que o kNN.

A Figura 98 apresenta os valores de erro de reconstrução obtido em cada Grupo de amostras analisado pelo classificador PCA, observando que todos os grupos têm o mesmo número de amostras.

As amostras de teste "Sem risco de queda" apresentam os menores valores de erro de reconstrução se comparado aos outros grupos com amostras "Com risco de queda" , com pouca dispersão nos valores de erro de reconstrução, assim apresenta poucos *outliers*. As amostras de todos os grupos com amostras "Com risco de queda" tem valores de erro de reconstrução acima do erro encontrado nas amostras "Sem risco de queda". Além disso, as amostras dos grupos apresentam mais dispersão resultando em mais *outliers*, indicando que muitas amostras com erro de erro acima do esperado para amostras "Sem risco de queda".

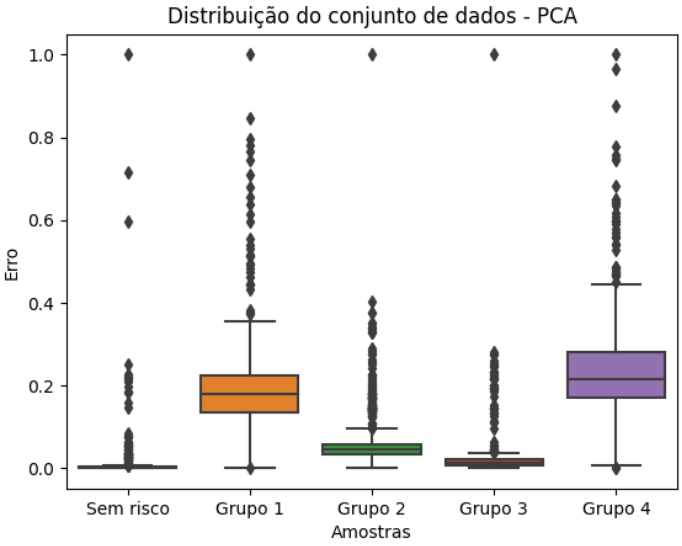

Figura 98: Distribuição do conjunto de dados para o classificador baseado em PCA com 3 CPs - validação *Hold-out*.

B.3 Classificador Baseado em Autoencoder

O classificador foi treinado aplicando o método de validação *Hold-out* por 3 modelos apresentados na Seção 3.3. O terceiro modelo é escolhido por apresenta melhor desempenho (maior AUC). As Curvas ROC na Figura 99 foram obtidas com amostras CSI de grupos da Seção 2.7 e 600 amostras de teste da classe "Sem risco de queda".

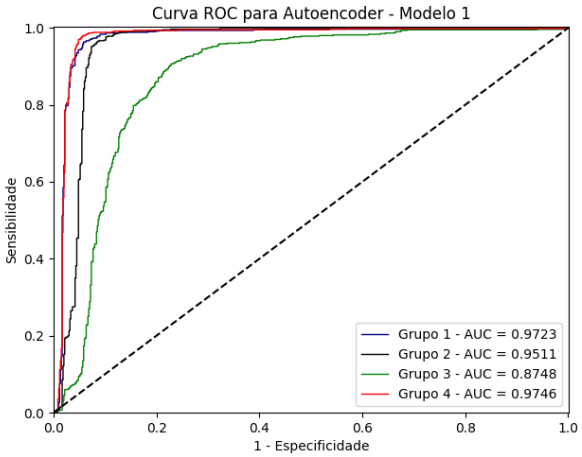

(a) Autoencoder Modelo 1

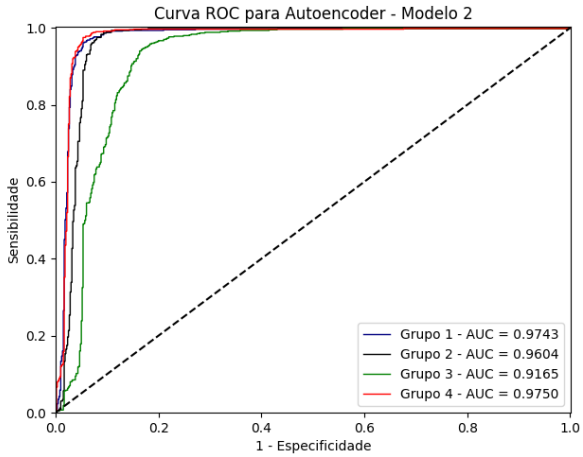

(b) Autoencoder Modelo 2

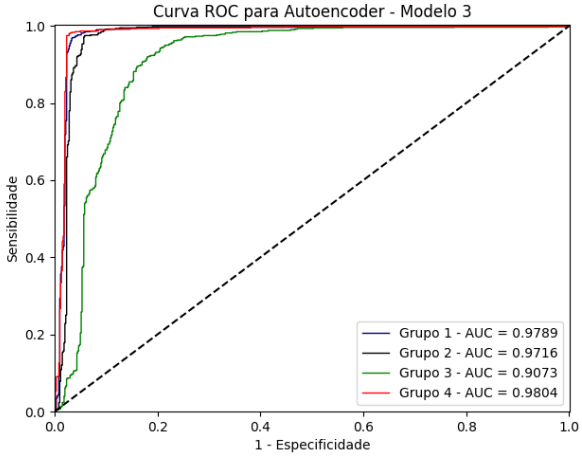

(c) Autoencoder Modelo 3

Figura 99: Curva ROC do classificador baseado em Autoencoder para diferentes modelos de Autoencoder - validação *Hold-out*.

- **Grupo 1**

  A Figura 100 as curvas de sensibilidade, especificidade e acurácia e a Figura 101 apresenta a posição dos pontos de corte na Curva ROC, onde o ponto de corte 1 é conservador em relação ao ponto de corte 2. Este grupo tem AUC de 0,9683.

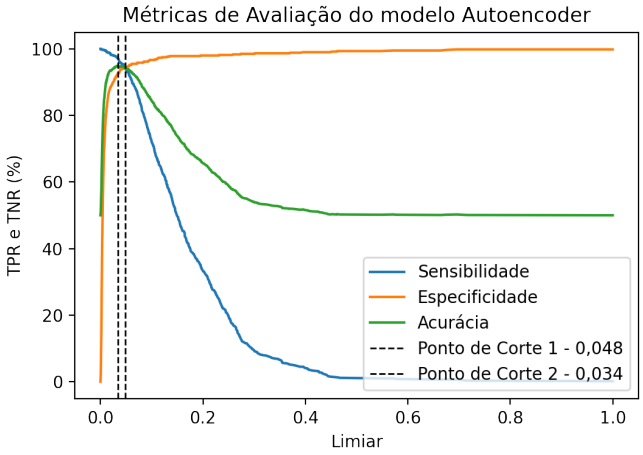

Figura 100: Localização dos pontos de corte do classificador baseado em Autoencoder - modelo 3 - Grupo 1 - validação *Hold-out*.

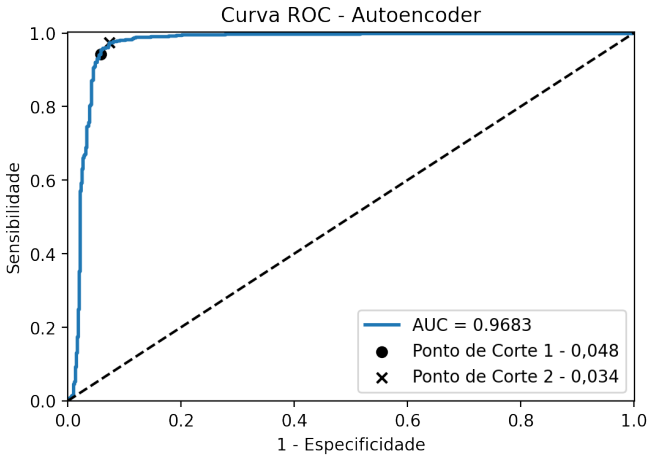

Figura 101: Localização dos pontos de corte na Curva ROC do classificador baseado em Autoencoder - modelo 3 - Grupo 1 - validação *Hold-out*.

A Figura 102(a) mostra a matriz de confusão do ponto de corte 1 com sensibilidade, especificidade e acurácia de 94,17% e possui 565 registros com acertos e 35 com erros em cada classe.

A Figura 102(b) mostra a matriz de confusão no ponto de corte 2, com sensibilidade de 97,33%, especificidade de 92,67% e acurácia de 95,00% e nas amostras previstas na classe "Com risco de queda" tem 584 verdadeiros positivos e 44 falsos positivos.

A Figura 102(c) mostra que as amostras previstas na classe "Com risco de queda", e observa-se que o ponto de corte 2 por ser menos conservador que o ponto de corte 1, tem capacidade de identificar corretamente mais amostras de risco, porém a diferença na quantidade de erros é pequena entre os dois pontos de corte.

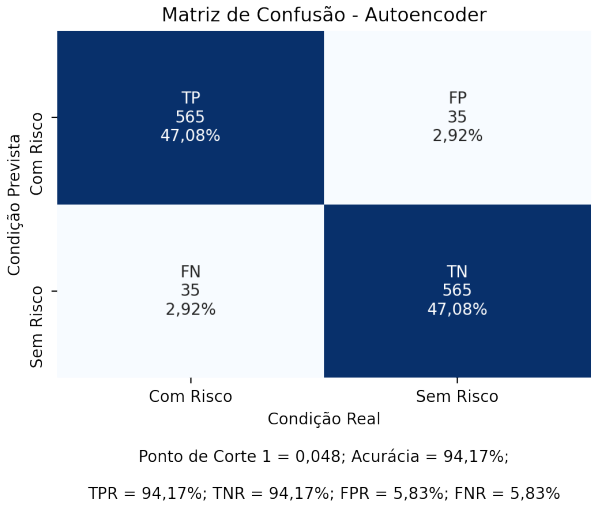

(a) Ponto de Corte 1

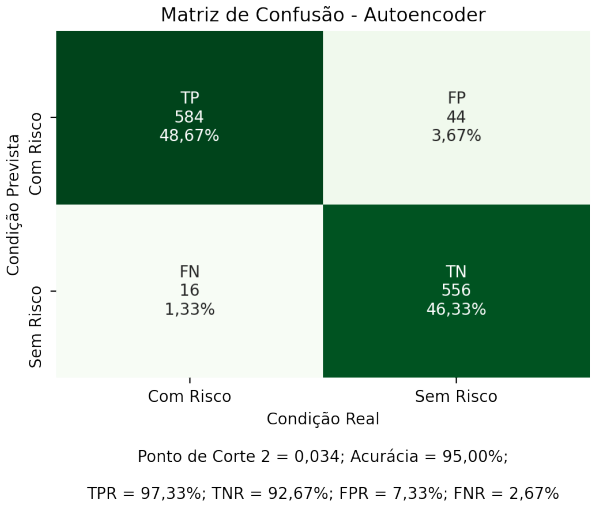

(b) Ponto de Corte 2

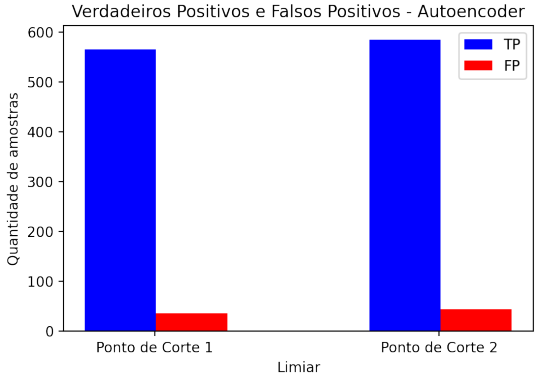

(c) Amostras previstas na classe "Com risco de queda" no Grupo 1.

Figura 102: Matriz de Confusão e amostras TP e FP dos pontos de corte no classificador baseado em Autoencoder - modelo 3 - Grupo 1 - validação *Hold-out*.

- **Grupo 2**

  A Figura 103 mostra as curvas de sensibilidade, especificidade e acurácia. A curva ROC da Figura 104 mostra a disposição dos pontos de corte, indicando que o ponto de corte 1 é conservador comparado ao ponto de corte 2, mas com valores de limiar próximos. Este grupo apresenta AUC de 0,9795.

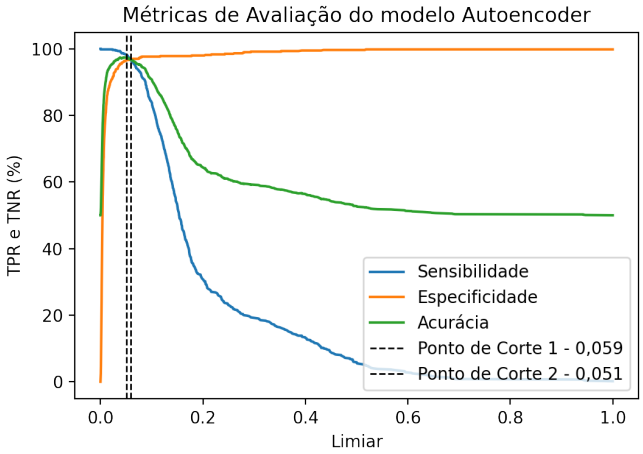

Figura 103: Localização dos pontos de corte do classificador baseado em Autoencoder - modelo 3 - Grupo 2 - validação *Hold-out*.

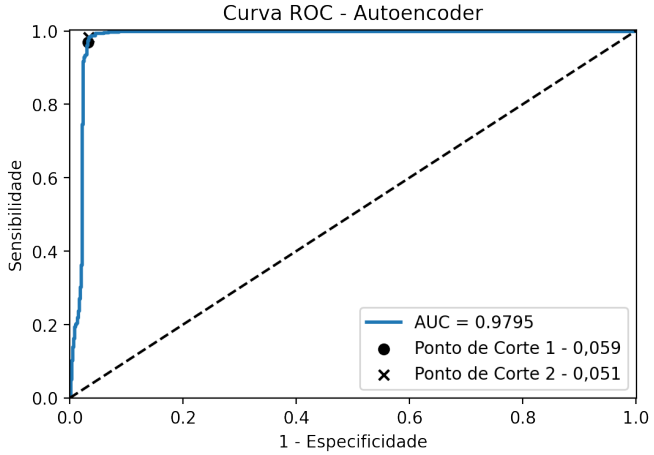

Figura 104: Localização dos pontos de corte na Curva ROC do classificador baseado em Autoencoder - modelo 3 - Grupo 2 - validação *Hold-out*.

A matriz de confusão na Figura 105(a) mostra que o ponto de corte 1 produz sensibilidade, especificidade e acurácia de 96,83%, com 581 amostras classificadas corretamente e 19 erros.

A matriz de confusão no ponto de corte 2, como mostra a Figura 105(b), as amostras

previstas da classe “Com risco de queda” tem 589 amostras verdadeiros positivas e 20 amostras falsos positivas. O ponto de corte possui sensibilidade de 98,17%, especificidade de 96,67% e acurácia de 97,42%.

A Figura 105(c) mostra os pontos de corte apresentam bom desempenho em relação às amostras verdadeiro positivas e poucas amostras de falsos positivos. Como o ponto de corte 1 é conservador quando comparado ao ponto de corte 2, são previstas menos amostras corretamente, porém os valores encontrados nos pontos de corte são parecidos. Com uso de um limiar mais flexível, como o ponto de corte 2, pode-se prever mais amostras de risco corretamente, com praticamente a mesma quantidade de amostras com erros nos dois pontos de corte.

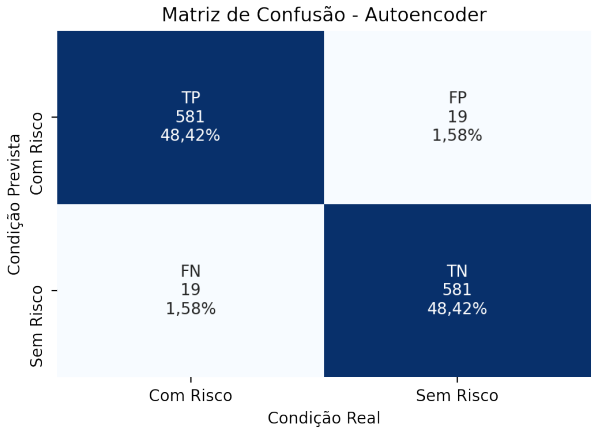

Ponto de Corte 1 = 0,059; Acurácia = 96,83%;

TPR = 96,83%; TNR = 96,83%; FPR = 3,17%; FNR = 3,17%

(a) Ponto de Corte 1

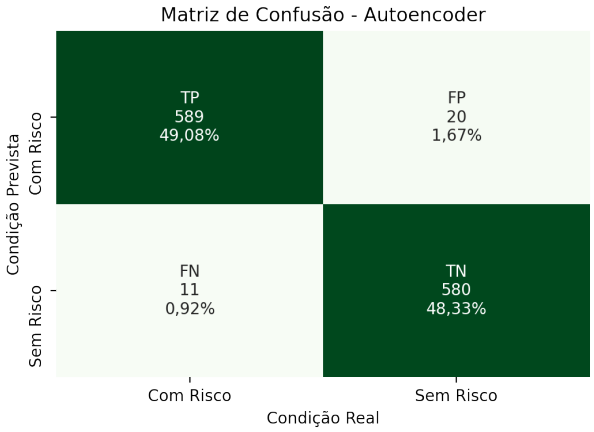

Ponto de Corte 2 = 0,051; Acurácia = 97,42%;

TPR = 98,17%; TNR = 96,67%; FPR = 3,33%; FNR = 1,83%

(b) Ponto de Corte 2

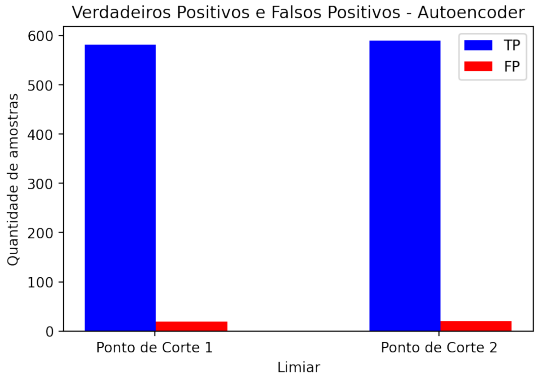

(c) Amostras previstas na classe “Com risco de queda” no Grupo 2.

Figura 105: Matriz de Confusão e amostras TP e FP dos pontos de corte no classificador baseado em Autoencoder - modelo 3 - Grupo 2 - validação *Hold-out*.

- **Grupo 3**

  A Figura 106 mostra as curvas de sensibilidade, especificidade e acurácia e a Figura 107 apresenta a curva ROC com a localização dos pontos de corte, com o ponto de corte 1 mais conservador que o ponto de corte 2 e AUC de 0,9156.

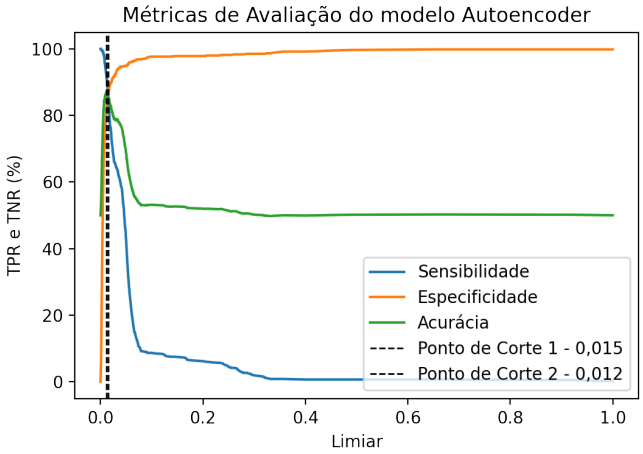

Figura 106: Localização dos pontos de corte do classificador baseado em Autoencoder - modelo 3 - Grupo 3 - validação *Hold-out*.

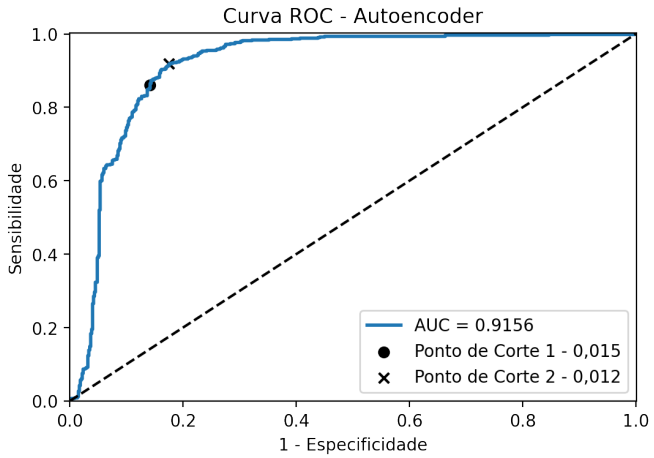

Figura 107: Localização dos pontos de corte na Curva ROC do classificador baseado em Autoencoder - modelo 3 - Grupo 3 - validação *Hold-out*.

A matriz de confusão dos pontos de corte 1, na Figura 108(a) mostra o ponto de corte tem sensibilidade 86,00%, especificidade de 85,83% e acurácia de 85,92%, com 516 amostras verdadeiro positivas e 85 amostras falso positivas.

No ponto de corte 2, como mostra a matriz de confusão da Figura 108(b), as amostras previstas da classe "Com risco de queda" possui sensibilidade de 91,83%, espe-

cificidade de 82,50% e acurácia de 87,17%, com 551 amostras verdadeiro positivas e 105 falsos positivos.

A Figura 108(c) mostra a quantidade de erros e acertos nos pontos de corte das amostras "Com risco de queda". Como o ponto de corte 2 é menos conservador que o ponto de corte 1, este ponto de corte produz mais amostras verdadeiro positivas e consequentemente, resulta em maior quantidade de amostras falsos positivas. Apesar disso, os dois pontos de corte tem capacidade de identificar corretamente a maior parte das amostras de risco, mas ainda, apresenta muitos erros (falsos positivos) com amostras "Com risco de queda" previstas incorretamente.

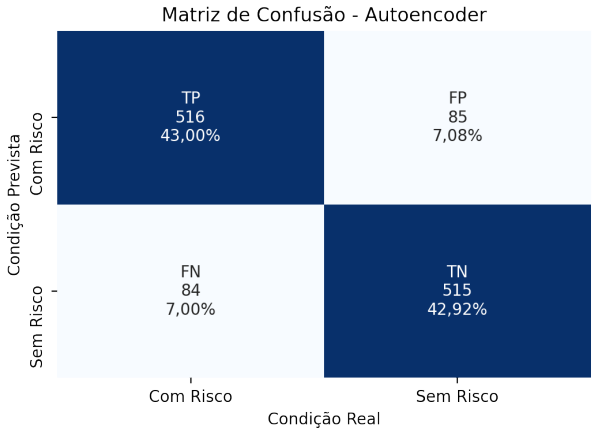

Ponto de Corte 1 = 0,015; Acurácia = 85,92%;

TPR = 86,00%; TNR = 85,83%; FPR = 14,17%; FNR = 14,00%

(a) Ponto de Corte 1

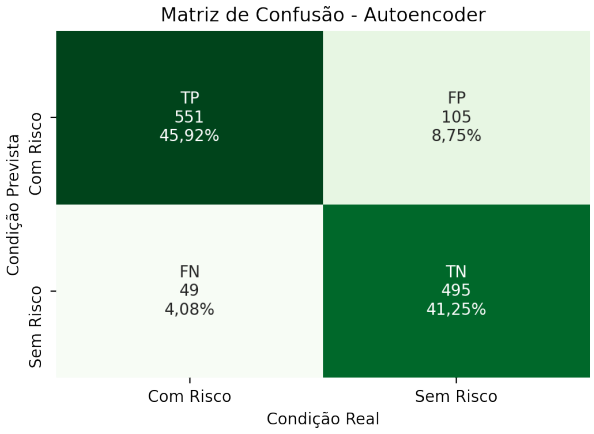

Ponto de Corte 2 = 0,012; Acurácia = 87,17%;

TPR = 91,83%; TNR = 82,50%; FPR = 17,50%; FNR = 8,17%

(b) Ponto de Corte 2

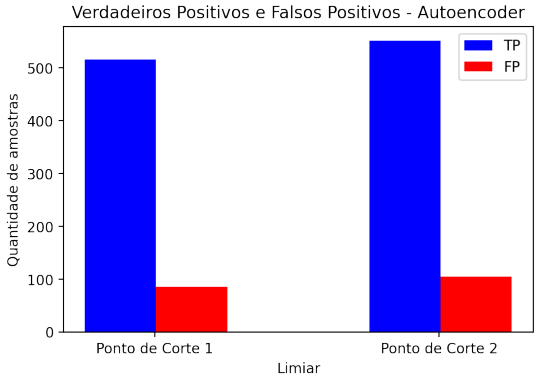

(c) Amostras previstas na classe "Com risco de queda" no Grupo 3.

Figura 108: Matriz de Confusão e amostras TP e FP dos pontos de corte no classificador baseado em Autoencoder - modelo 3 - Grupo 3 - validação *Hold-out*.

- **Grupo 4**

  A Figura 109 mostra as curvas de sensibilidade, especificidade e acurácia. A curva ROC na Figura 110 apresenta a posição dos pontos de corte na curva ROC, indicando que o ponto de corte 1 é conservador, então espera-se que neste ponto de corte tenha menos amostras "Com risco de queda" previstas corretamente e também menos erros que o ponto de corte 2. Esta configuração tem AUC de 0,9819.

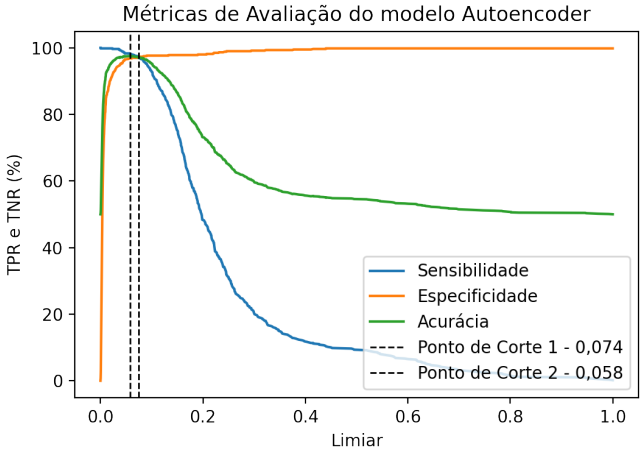

Figura 109: Localização dos pontos de corte do classificador baseado em Autoencoder - modelo 3 - Grupo 4 - validação *Hold-out*.

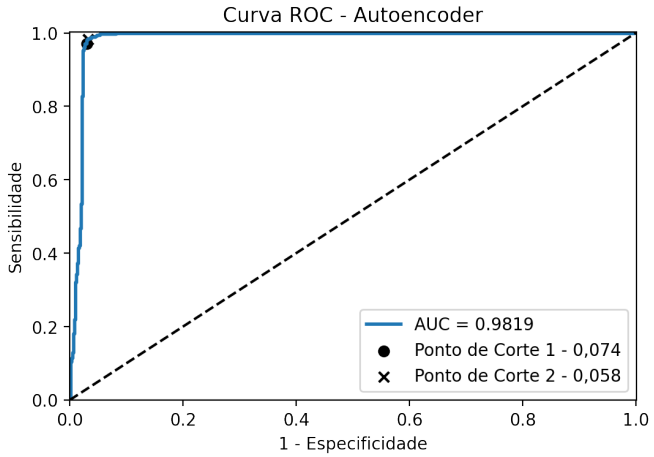

Figura 110: Localização dos pontos de corte na Curva ROC do classificador baseado em Autoencoder - modelo 3 - Grupo 4 - validação *Hold-out*.

A matriz de confusão do ponto de corte 1, na Figura 111(a), mostra que o ponto de corte tem sensibilidade, especificidade e acurácia de 97,00%, com 581 amostras corretas e 19 erros em cada classe.

O ponto de corte 2 da Figura 111(b) tem sensibilidade de 98,33%, especificidade de 96,83% e acurácia de 97,58%. E apesar do ponto de corte 2 ser menos conservador que o ponto de corte 1, é possível identificar 590 amostras verdadeiro positivas e 19 amostras falso positivas, com pequena diferença em relação ao ponto de corte 1.

A Figura 111(c) mostra o desempenho semelhante nos dois pontos de corte em relação às amostras previstas na classe "Com risco de queda", com o ponto de corte 2 prevendo mais amostras verdadeiro positivas com pequena diferença em relação aos falsos positivos (erros).

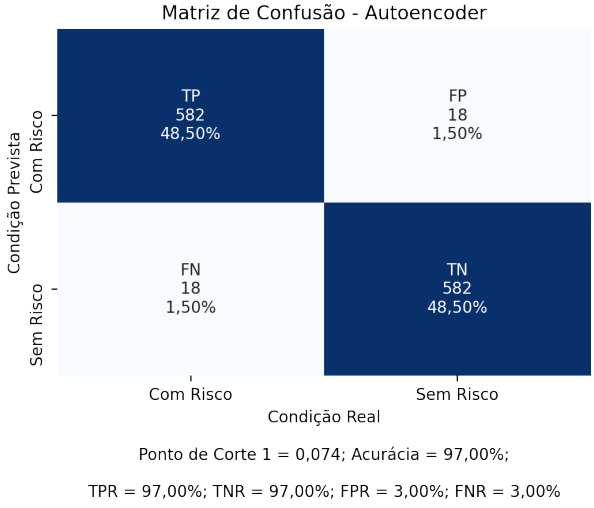

(a) Ponto de Corte 1

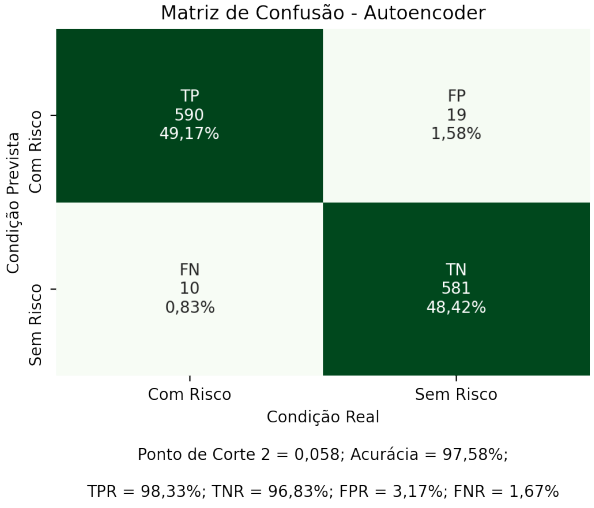

(b) Ponto de Corte 2

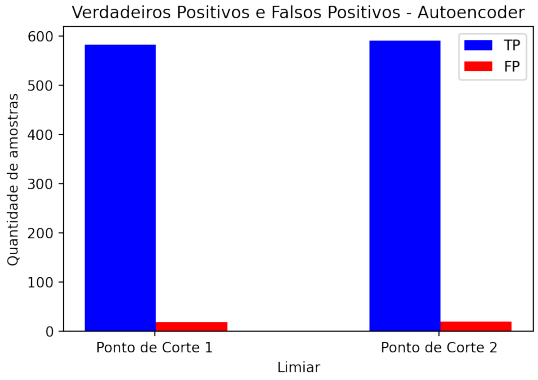

(c) Amostras previstas na classe "Com risco de queda" no Grupo 4.

Figura 111: Matriz de Confusão e amostras TP e FP dos pontos de corte no classificador baseado em Autoencoder - modelo 3 - Grupo 4 - validação *Hold-out*.

B.3.1 Análise dos Resultados do Classificador Autoencoder

Como nos outros classificadores, o desempenho é avaliado a partir da acurácia, percentual de amostras previstas corretamente nas duas classes. O classificador baseado em Autoencoder apresenta bons resultados de acurácia nos grupos com amostras da classe "Com risco de queda", como mostra a Tabela 19.

Tabela 19: Acurácia para os diferentes grupos no Classificador baseado em Autoencoder - modelo 3 - validação *Hold-out*.

Grupos	**Acurácia**	
	Ponto de Corte 1	**Ponto de Corte 2**
Grupo 1	94,17%	97,33%
Grupo 2	96,83%	97,42%
Grupo 3	85,92%	87,17%
Grupo 4	97,00%	97,58%

Quando comparado o Autoencoder para análise por grupos com os outros classificadores, PCA e kNN, observa-se que este classificador apresenta melhor desempenho, bem próximo do obtido no classificador baseado em PCA. Nota-se pelos resultados, que os classificadores baseado em PCA e Autoencoder tem melhor capacidade para identificação de amostras de risco de queda.

A Figura 112 mostra a distribuição do erro de reconstrução nos conjuntos de dados analisado por esse classificador. Todos os grupos com amostras da classe "Com risco de queda" apresentam erro de reconstrução acima do obtido nas amostras da classe "Sem risco de queda". Além disso, as amostras da classe "Com risco de queda" tem maior dispersão, indicando mais *outliers* que as amostras "Sem risco de queda".

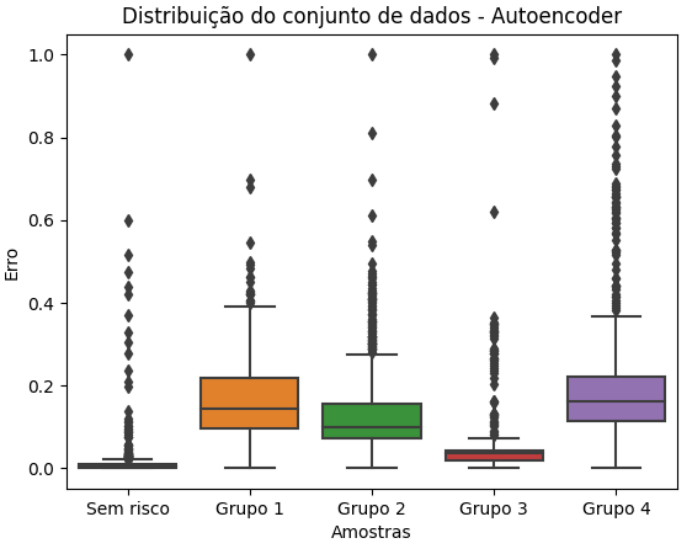

Figura 112: Distribuição do conjunto de dados para o classificador baseado em Autoencoder - modelo 3 - validação *Hold-out*.

B.4 Sumário Comparativo entre os Classificadores para as Diferentes Situações de Risco de Queda

Nesta seção é apresentado o comparativo através da acurácia para os três classificadores, onde as amostras separadas em grupos com uso da validação *Hold-out*. A Tabela 20 mostra a acurácia no pontos de corte 1 e a Tabela 21 no ponto de corte 2.

Tabela 20: Acurácia (%) dos classificadores no ponto de corte 1 - validação *Hold-out*.

	Classificadores		
Grupo	**kNN**	**PCA**	**Autoencoder**
1	95,33%	96,17%	94,17%
2	90,67%	91,00%	96,83%
3	66,83%	87,50%	85,92%
4	94,00%	96,83%	97,00%

Tabela 21: Acurácia (%) dos classificadores no ponto de corte 2 - validação *Hold-out*.

	Classificadores		
Grupo	**kNN**	**PCA**	**Autoencoder**
1	96,08%	96,58%	97,33%
2	91,17%	94,00%	97,42%
3	69,25%	89,42%	87,17%
4	94,42%	96,92%	97,58%

Observa-se que o classificador kNN apresenta menor acurácia se comparado aos outros classificadores. Os classificadores PCA e Autoencoder apresentam bom desempenho, com valores próximos de acurácia, indicando boa capacidade para identificação de amostras de risco de queda e o ponto de corte 2 apresenta melhor desempenho em todos os classificadores.