



CATOLICA
ESCOLA SUPERIOR DE BIOTECNOLOGIA

PORTO

**AVALIAÇÃO CARDÍACA DO PADRÃO DE
RESPONSIVIDADE À CAFEÍNA ATRAVÉS DE
MÉTODOS DE APRENDIZAGEM COMPUTACIONAL**

por

Ana Rita Queirós Domingues

dezembro 2022



CATÓLICA
ESCOLA SUPERIOR DE BIOTECNOLOGIA

PORTO

**AVALIAÇÃO CARDÍACA DO PADRÃO DE
RESPONSIVIDADE À CAFEÍNA ATRAVÉS DE
MÉTODOS DE APRENDIZAGEM COMPUTACIONAL**

Tese apresentada à Escola Superior de Biotecnologia da Universidade Católica
Portuguesa para obtenção do grau de Mestre em Engenharia Biomédica

por

Ana Rita Queirós Domingues

Orientador: Prof. Doutor Pedro Miguel de Luís Rodrigues

Coorientador: Prof.^a Doutora Patrícia Oliveira-Silva

dezembro 2022

Resumo

Aproximadamente 80% da população adulta mundial consome um produto cafeinado diariamente e, ao contrário de outras drogas, o consumo acontece em todos os níveis socioeconômicos. Além do custo-benefício, a cafeína atua como um poderoso estimulante do sistema nervoso central com efeitos fisiológicos muito apelativos ao consumidor, especialmente a nível cognitivo e da *performance* física. A forma de administrar esta substância psicoativa parece influenciar a resposta do organismo e, por isso, estudos têm sido desenvolvidos a fim de encontrar soluções mais eficientes. A entrega de cafeína através dos *Oral Films* (OF) representa uma grande oportunidade para os investigadores. De forma a colmatar a lacuna científica nesta área, tirou-se partido da influência da cafeína sobre a modulação da atividade do sistema nervoso, através do rastreamento da variabilidade da atividade cardíaca, em indivíduos saudáveis sujeitos ao consumo de diferentes modalidades de cafeína: café, descafeinado, OF_cafeína e OF_placebo. Considerando a era científico-tecnológica em que vivemos, e no sentido de maximizar a capacidade discriminativa dos sinais eletrocardiográficos (ECG), tirou-se partido da sua natureza dinâmica com recurso a métodos robustos de processamento de sinal e técnicas de Inteligência Artificial para estudar as comparações binárias descafeinado/café e OF_placebo/OFCafeína. Assim, após os ECG serem submetidos a uma análise multibanda através da Transformada Wavelet Discreta (DWT), para todos os 5 níveis de decomposição, foram extraídas as métricas energia, entropia, expoente de Lyapunov, expoente de Hurst e dimensão fractal de Higuchi. Estas métricas alimentaram 23 modelos de classificação num processo de validação cruzada em *leave-one-out*, a cada 1 min. Para otimizar o processo de classificação, selecionaram-se automaticamente as métricas que melhor descrevem os sinais, removendo informações redundantes e evitando o *overfitting*, recorrendo-se ao treino classificativo com a Análise de Componentes Principais (PCA) a 100%, 80%, 70%, 50%, 20%, 10%, 5% e 1%. Para compreender a evolução temporal do efeito fisiológico das modalidades no organismo, foram traçadas curvas de precisão de 50 min com resolução de 1 min, para cada comparação binária, para todos os classificadores e para todos os treinos com PCA. Face ao elevado volume de dados, a decisão do classificador que melhor discrimina as modalidades em cada comparação binária foi efetuada com base na precisão média das curvas de precisão. Os resultados das análises individuais revelaram os melhores valores de precisão média para os classificadores de árvore de decisão no treino com PCA 100% (50,2%) e *Fine Gaussian* no treino com PCA 95% (72%), para as comparações descafeinado/café e OF_placebo/OFCafeína, respetivamente. Ainda assim, existem picos discriminativos de maior amplitude ao longo do tempo que são camuflados pela precisão média. As curvas de precisão revelaram, ao contrário da comparação descafeinado/café, diferenças significativas ao longo do tempo entre o OF_placebo e o OF_cafeína, evidenciando que o consumo de cafeína através de OF revela capacidade efetiva em relação ao seu placebo. Entretanto, no caso da comparação descafeinado/café, os resultados apontam para que o descafeinado não constitua um verdadeiro placebo do café. O principal fator aponta para o facto de que ambas as modalidades foram servidas da mesma máquina e resíduos de cafeína podem ter passado para a bebida descafeinada.

Palavras – chaves: Cafeína, Café, *Oral Films*, Eletrocardiograma, Análise não linear, Transformada Wavelet Discreta, *Machine Learning*

Abstract

Approximately 80% of the adult population worldwide consumes one caffeinated product on a daily basis and, as opposed to other drugs, the consumption happens in every socioeconomic level. In addition to the cost-benefit, caffeine acts as a powerful stimulant to the central nervous system, causing physiological effects that are very appealing to the consumer, specifically on a cognitive level and in terms of physical performance. The way in which this psychoactive substance is administered seems to influence the body's response and, therefore, studies have been developed to find more efficient solutions. Caffeine delivery through Oral Films (OF) constitutes a great opportunity for researchers. In order to bridge this area's scientific gap, advantage was taken from the impact that caffeine has on the modulation of the nervous system's activity by tracking the variability of cardiac activity in healthy individuals that were subject to the consumption of different caffeine modalities: coffee, decaffeinated coffee, OF_caffeine and OF_placebo. Taking into consideration the scientific and technological age we live in, and in an attempt to maximize the discriminating capability of electrocardiographic signals (ECG), its dynamic nature was exploited using robust signal processing methods and Artificial Intelligence techniques in order to analyze the binary comparisons decaffeinated coffee/coffee and OF_placebo/OFCaffeine. Therefore, after subjecting the ECGs to a multi-band analysis through the use of the Discrete Wavelet Transform (DWT), metrics were extracted for all the 5 decomposition levels: energy, entropy, Lyapunov exponent, Hurst exponent and Higuchi's fractal dimension. These metrics fed 23 classification models every minute, in a leave-one-out cross-validation process. In order to optimize the classification process, the metrics that better describe the signals were automatically selected, removing redundant information and avoiding overfitting, resorting to classifying training with the Principal Component Analysis (PCA) at 100%, 80%, 70%, 50%, 20%, 10%, 5% and 1%. In order to understand the development of the modalities' physiological effect on the body over time, 50 min accuracy curves with 1 min resolution were outlined for every binary comparison, classifier and PCA training. In view of the high volume of data, the classifier's decision that better specifies the modalities in each binary comparison was made based on the average accuracy of the accuracy curves. The individual analysis' results showed the best average accuracy values for the decision tree classifiers in PCA training with PCA 100% (50.2%) and Fine Gaussian in training with PCA 95% (72%) for decaffeinated coffee/coffee and OF_placebo/OFCaffeine comparisons, respectively. Nevertheless, there are higher amplitude discriminatory peaks camouflaged by the average accuracy over time. In contrast with the decaffeinated coffee/coffee comparison, the accuracy curves showed significant differences between the OF_placebo and the OF_caffeine over time, pointing out that caffeine intake through OF shows effective capacity when compared to its placebo. Meanwhile, as far as the decaffeinated coffee/coffee comparison is concerned, the results point to the fact that decaffeinated coffee may not be a real coffee placebo. In this analysis, the main factor highlights that both modalities were prepared using the same machine and that it is possible that the decaffeinated beverage got caffeine residue.

Keywords: Caffeine, Coffee, Oral Films, Electrocardiogram, Nonlinear analysis, Discrete Wavelet Transform, Machine Learning

Agradecimentos

Em primeira instância, expresso a minha enorme gratidão ao meu orientador, Professor Doutor Pedro Miguel de Luís Rodrigues, pela dedicação, orientação, disponibilidade, motivação e confiança que me transmitiu ao longo da realização da dissertação e durante todo o meu percurso académico nas várias cadeiras que lecionou. Do fundo do coração, uma palavra de apreço pela compreensão e pelo encorajamento num dos momentos mais difíceis da minha vida.

Agradecer também à minha coorientadora, Professora Doutora Patrícia Oliveira-Silva, pelos conhecimentos transmitidos, entrega e apoio prestados e, sobretudo pelo entusiasmo com que viveu e me fez viver a temática que foi aqui explorada.

Um agradecimento muito especial a esta instituição de ensino, Escola Superior de Biotecnologia da Universidade Católica Portuguesa do Porto, e a todos os profissionais que se cruzaram no meu caminho e contribuíram para a minha formação académica e pessoal. A todos os professores, que levarei no meu coração para toda a vida, agradeço o conhecimento, a confiança, os conselhos, a paciência e, principalmente a exigência e excelência que sempre me impuseram. Em particular e pelo qual nutro uma grande estima e respeito, ao Professor Doutor João Paulo Ferreira, que acreditou em mim desde o primeiro ano da faculdade e, desde então, me presenteia sempre com palavras de sabedoria, coragem e motivação.

À minha família pelo amor desmedido, pelo incentivo nos momentos mais desafiantes, por acreditarem sempre nas minhas decisões e estarem presentes em todas as fases da minha vida. Ao meu avô paterno, Castro Domingues, que infelizmente observou todo o meu percurso universitário através das estrelas, agradeço a menina-mulher que ajudaste a construir. Esta dissertação culmina o último esforço para alcançar o título de Engenheira Mestre e, por isso, é dedicada a ti. Sei que estás muito orgulhoso pela tua “*Sr.ª Engenheira*” e que hoje a chuva são lágrimas de felicidade.

Ao João, o meu namorado e companheiro desde há 8 anos, faltam-me as palavras para expressar tamanho amor e orgulho. Posso resumir tudo dizendo que ele é a maior prova de amor e o maior exemplo de força e resiliência. Dia 13 de novembro de 2020, sexta-feira, o João visitou o meu avô nas estrelas e regressou à sua segunda oportunidade de viver esta curta passagem, a qual designo a dádiva de viver. A ciência não consegue explicar o milagre e, desta forma, nada mais me cabe a mim acrescentar.

Por fim, uma menção muito especial à minha companheira de quatro patas. A ti, Mel, obrigada pelo amor incondicional e pelo olhar ternurento que enchem o meu coração nos momentos difíceis. Requeseres muita atenção e longos passeios para gastares a tua energia infinita, mas graças a isso, todos os dias de manhã bem cedo, tenho a sorte de contemplar a natureza e restabelecer as baterias anímicas para os longos dias de trabalho.

Eternamente agradecida, por fazerem parte desta etapa tão importante da minha vida!

Rita Domingues

“ ξέρω μόνο ότι δεν ξέρω τίποτα “

“ Só sei que nada sei “

Sócrates [470 a.c – 399 a.c]

Índice

Resumo	I
Abstract	III
Agradecimentos	V
Índice de ilustrações	XI
Índice de tabelas	XIII
Abreviaturas e Acrónimos	XV
1 Introdução	1
1.1 Motivação	1
1.2 Objetivos	2
1.3 Estrutura da Dissertação	2
2 Revisão Bibliográfica	3
2.1 Cafeína e o Organismo Humano	3
2.2 <i>Oral films</i> de cafeína	5
2.3 Estado da arte	7
3 Sinal Biomédico	9
3.1 Coração	9
3.2 Eletrocardiograma	11
4 Processamento de Sinal	13
4.1 Transformada Wavelet Discreta	13
4.2 Análise não linear	16
4.2.1 Teoria do caos	16
4.2.1.1 Expoente de Lyapunov	16
4.2.1.2 Expoente de Hurst	17
4.2.2 Dimensão Fractal	17
4.2.3 Energia e Entropia	18
5 Métodos de Classificação	19
5.1 X-ROC	19
5.2 Árvore de Decisão	20
5.3 Análise Discriminante	21
5.4 Regressão Logística	21
5.5 <i>Naïve Bayes</i>	22
5.6 <i>Support Vector Machines</i>	23
5.7 <i>K-Nearest-Neighbors</i>	24

5.8 Aproximação de Kernel	26
5.9 <i>Ensemble Learning</i>	26
5.10 Avaliação do desempenho dos classificadores	29
5.10.1 Validação Cruzada	29
5.10.2 Medidas de apoio à decisão e Seleção de parâmetros	29
6 Metodologia	31
6.1 Base de Dados	31
6.2 Estrutura da Investigação	33
6.3 Apresentação e Discussão dos Resultados	37
7 Conclusão e Perspetivas Futuras	47
Apêndices	49
Apêndice A - Precisão dos Classificadores com PCA=100%	49
Apêndice B - Precisão dos Classificadores com PCA=95%	61
Apêndice C - Precisão dos Classificadores com PCA=80%	73
Apêndice D - Precisão dos Classificadores com PCA=70%	85
Apêndice E - Precisão dos Classificadores com PCA=50%	97
Apêndice F - Precisão dos Classificadores com PCA=20%	109
Apêndice G - Precisão dos Classificadores com PCA=10%	121
Apêndice H - Precisão dos Classificadores com PCA=5%	133
Apêndice I - Precisão dos Classificadores com PCA=1%	145
Referências	157

Lista de Figuras

Figura 3.1. Sistema de condução do coração [Adaptado de [68]].	10
Figura 3.2. Traçado típico de ECG [Adaptado de [67]].	11
Figura 3.3. Princípios básicos na medição de ECG [Adaptado de [71]].	12
Figura 4.1 Aplicação da DWT [Adaptado de [73]].	15
Figura 5.1 Teste hipotético que visa classificar dois grupos: A e B. (a) Representação das curvas de distribuição e (b) respetiva Curva ROC. O Ponto A1 representa o valor de corte associado a maior sensibilidade e especificidade. O Ponto A2 representa o valor de corte com a máxima sensibilidade (ausência de falsos positivos). O Ponto A3 é o valor de corte associado a máxima especificidade, abaixo do qual não se verificam falsos negativos [Adaptado de [113]].	20
Figura 5.2 Ilustração típica do algoritmo Árvore de Decisão [Adaptado de [114]].	20
Figura 5.3 Processo de classificação por Análise Discriminante [Adaptado de [118]].	21
Figura 5.4 Curva logística quando $\alpha=0$ e $\beta=1$. Quando a resposta y consiste numa variável binária (dicotómica) e x é numérica, a função logística ajusta uma curva representativa da relação entre estas variáveis $y=f(x)$ [Fonte [121]].	22
Figura 5.5 Hiperplanos de separação. (a) Em geral, existe um número infinito de hiperplanos de separação possíveis, sugerindo <i>overfitting</i> . SVM procura encontrar o hiperplano ideal que terá o mínimo de erro de classificação. Como tal, consideremos (b) que apresenta dois hiperplanos possíveis e as respetivas margens associadas. Verificamos que ambos classificam corretamente todas as instâncias, no entanto, para classificação de dados futuros é conveniente utilizar o modelo de margem maior por ter maior precisão – hiperplano marginal máximo [Adaptado de [130]].	24
Figura 5.6 Classificação por KNN [Adaptado de [136]].	25
Figura 5.7 Método de Kernel. Aplicando a função de Kernel ϕ a um espaço de baixa dimensão, consegue-se separar linearmente as classes num espaço de atributos de alta dimensão [Adaptado de [142]].	26
Figura 5.8 Métodos de Bagging e Boosting [Adaptado de [148]].	27
Figura 5.9 Método de subespaço aleatório [Adaptado de [150]].	28
Figura 5.10 <i>Cross-Validation</i> com <i>k-folds</i> [Adaptado de [157]].	29
Figura 6.1 Estrutura do algoritmo desenvolvido com base na metodologia adotada.	34
Figura 6.2 Curvas de precisão dos classificadores com os melhores resultados para ambas as classificações binárias, quando o sistema foi treinado com PCA=100%.	39
Figura 6.3 Curvas de precisão dos classificadores com os melhores resultados para ambas as classificações binárias, quando o sistema foi treinado com PCA=95%.	40
Figura 6.4 Curvas de precisão dos classificadores com os melhores resultados para ambas as classificações binárias, quando o sistema foi treinado com PCA=80%.	40

Figura 6.5 Curvas de precisão dos classificadores com os melhores resultados para ambas as classificações binárias, quando o sistema foi treinado com PCA=70%.....	41
Figura 6.6 Curvas de precisão dos classificadores com os melhores resultados para ambas as classificações binárias, quando o sistema foi treinado com PCA=50%.....	41
Figura 6.7 Curvas de precisão dos classificadores com os melhores resultados para ambas as classificações binárias, quando o sistema foi treinado com PCA=20%.....	42
Figura 6.8 Curvas de precisão dos classificadores com os melhores resultados para ambas as classificações binárias, quando o sistema foi treinado com PCA=20%.....	42
Figura 6.9 Curvas de precisão dos classificadores com os melhores resultados para ambas as classificações binárias, quando o sistema foi treinado com PCA=5%.....	43
Figura 6.10 Curvas de precisão dos classificadores com os melhores resultados para ambas as classificações binárias, quando o sistema foi treinado com PCA=1%.....	44
Figura 6.11 Comparação dos resultados selecionados para cada classificação binária.	45
Figura 6.12 Curvas de precisão dos classificadores com os melhores resultados da investigação. ..	45

Lista de Tabelas

Tabela 4.1 Propriedades das famílias Wavelet mais comuns e importantes [77].	14
Tabela 5.1 Modelo de classificação ajustando o número de pontos vizinhos [77].	25
Tabela 5.2 Modelo de classificação ajustando a métrica avaliativa da distância [77].	25
Tabela 5.3 Classificadores <i>Ensemble Learning</i> [77].	28
Tabela 5.4 Matriz de confusão (ou tabela de contingência).	30
Tabela 6.1 Caracterização da amostra a nível sociodemográfico [57].	32
Tabela 6.2 Caracterização da amostra quanto ao padrão do perfil do consumo de cafeína [57].	32
Tabela 6.3 Os vinte e três modelos de classificação e os seus classificadores correspondentes [77, 165].	36

Abreviaturas e Acrónimos

1D	Unidimensional
ANT	<i>Attentional Network Test</i>
Bior	Biortogonal
Coif	Coiflet
Db	Daubechies
DWT	<i>Discrete Wavelet Transform</i>
ECG	Sinal Eletrocardiográfico
EDA	Atividade Eletrodérmica
FDA	<i>American Food and Drug Administration</i>
FN	Falso Negativo
FP	Falso Positivo
<i>H</i>	Expoente de Hurst
HFD	<i>Higuchi Fractal Dimension</i>
KNN	<i>K-Nearest-Neighbors</i>
Meyr	Meyer
OCDE	Organização para a Cooperação e Desenvolvimento Econômico
OF	<i>Oral Films</i>
PCA	<i>Principal Component Analysis</i>
rBio	Biortogonal Reversa
Sym	Symlet
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo
WT	<i>Wavelet Transform</i>
SVM	<i>Support Vector Machines</i>
T.O.V.A	<i>Test of variables of attention</i>
X-ROC	<i>Receiver Operating Characteristic</i>

Introdução

1.1 Motivação

Um dos principais motores do avanço da ciência é a curiosidade humana. Este elemento básico do desenvolvimento cognitivo é a chave para solucionar a grande aspiração da humanidade: viver mais tempo, com melhores condições e com mais saúde [1]. Efetivamente, durante séculos, a ciência e a tecnologia têm contribuído em larga escala para a melhoria da qualidade de vida. De acordo com a Organização para a Cooperação e Desenvolvimento Econômico (OCDE), uma pessoa nascida no final do século XVIII muito provavelmente morreria antes de completar 40 anos de idade. Atualmente, num país desenvolvido a esperança média de vida ultrapassa os 80 anos e, embora a desigualdade seja notória, mesmo nos países mais pobres de África do Sul, esse parâmetro estatístico aponta para uma vivência média de 60 anos [2].

Concomitante ao avanço científico-tecnológico e, influenciando diretamente a qualidade de vida do ser humano, estão as drogas. Em particular, aquelas capazes de ultrapassar a barreira hematoencefálica e provocar os efeitos desejados, designadas por substâncias psicoativas. O estudo destas substâncias revela-se, então, um dos principais desafios atuais e centrais na comunidade científica, que se estende pelas áreas da saúde, farmacologia, investigação, cosmética e mesmo áreas relacionadas com o desporto, na tentativa de otimizar a *performance* dos atletas [3, 4].

A cafeína é a substância psicoativa mais consumida a nível mundial, principalmente motivada pelos efeitos fisiológicos que provoca no organismo a nível cognitivo e a nível do desempenho físico. A promoção de estado de alerta, concentração, excitação, energia e humor elevado é bastante aliciante, tendo promovido uma tendência crescente na introdução de produtos cafeinados no mercado [5, 6]. Estas mudanças nos padrões de consumo despertam grande interesse a nível do impacto na saúde humana, revelando-se este, um tema em discussão há vários anos. Contudo, os resultados na comunidade científica não são claros, nomeadamente quanto à forma de administração de cafeína dada a grande variabilidade de produtos cafeinados disponível no mercado [7]. Torna-se, por isso, impreterível desenvolver trabalhos científicos nesta área, tornando este trabalho pioneiro mais desafiante e entusiasmante.

1.2 Objetivos

Movida pela curiosidade, a consumação desta dissertação visa avaliar o impacto fisiológico da cafeína no organismo humano, quando consumida sob a forma de café ou *Oral Films* (OF), pela combinação de informação extraída de sinais eletrocardiográficos (ECG) e métodos de Inteligência Artificial. Para tal, pretende-se desenvolver um algoritmo capaz de processar esses sinais fisiológicos no sentido de avaliar métricas identificativas desta substância psicoativa, em diferentes momentos temporais da aquisição de sinal.

1.3 Estrutura da Dissertação

A presente dissertação será estruturada em sete capítulos: o **capítulo 1** introduz o tema a ser explorado e esclarece os principais objetivos e motivações do autor para a sua concretização; o **capítulo 2** é dedicado a uma revisão bibliográfica sobre a interação da cafeína com o organismo humano, o seu consumo através de OF e a apresentação do estado da arte; o **capítulo 3** explica conceitos relacionados com sinais biomédicos e aquisição de sinal, focando-se na atividade cardíaca; os **capítulos 4 e 5** descrevem as técnicas de processamento de sinal e os métodos de classificação utilizados na metodologia, para que o leitor se familiarize e compreenda os conceitos teóricos; o **capítulo 6** aborda a metodologia adotada e apresenta e discute os respetivos resultados; por fim, o **capítulo 7** reúne as conclusões mais relevantes e sugere futuras perspetivas de investigação.

Revisão Bibliográfica

2.1 Cafeína e o Organismo Humano

A cafeína, nome comum para 1,3,7-trimetilxantina, foi descoberta em 1819 pelo químico alemão Friedlieb Ferdinand Runge quando analisava grãos de café [8]. A etimologia da palavra surge, então, do alemão *kaffee* que significa café. Esta pequena molécula é um alcaloide encontrado em mais de 60 espécies de plantas, amplamente distribuídas por diferentes regiões geográficas. Algumas das fontes vegetais mais conhecidas são grãos de café e de cacau, as folhas de chá verde, a noz de cola, o guaraná e a erva-mate. Entretanto, no final do século XIX, o mercado de refrigerantes cafeinados começa a crescer com a introdução da Coca-Cola. O aumento da popularidade de bebidas contendo maiores quantidades de cafeína inspirou a chegada de bebidas energéticas e suplementos alimentares, que se tornaram muito prevalentes. Atualmente, aproximadamente 80% da população adulta mundial consome um produto cafeinado todos os dias e, ao contrário de outras drogas, o consumo acontece em todos os níveis socioeconômicos [3, 9, 10].

Após a administração via oral ou parenteral, a cafeína é rapidamente absorvida e a biodisponibilidade absoluta em adultos atinge cerca de 100%. Em apenas 20 minutos, aproximadamente 90% desta substância é absorvida e o pico de concentração plasmática ocorre entre os 40 a 90 minutos [9, 11]. Face à sua natureza bioquímica, a cafeína consegue ultrapassar todas as membranas biológicas, incluindo a barreira hematoencefálica sendo, por isso, considerada uma substância psicoativa [11]. A substância mantém-se na corrente sanguínea por um período de semivida de 5 horas, exercendo uma variedade alargada de ações fisiológicas em diversos órgãos do corpo, nomeadamente no sistema nervoso central [12]. O principal mecanismo de ação da cafeína é funcionar como antagonista do recetor de adenosina, e desta forma, atua como um poderoso estimulante do sistema nervoso central [13]. Mediante a interação com estes recetores, a cafeína consegue interferir com a ação de vários neurotransmissores, nomeadamente a adenosina, a serotonina, a dopamina, o glutamato, a adrenalina e a noradrenalina [14]. Apesar do impacto da cafeína no organismo humano resultar da interação destas moléculas em uníssono, é interessante compreender o comportamento isolado de cada uma.

Por terem estruturas moleculares semelhantes, a cafeína tem o potencial de ocupar os recetores de adenosina acabando por impedir a ação desta molécula. Como a adenosina medeia a perceção de sonolência, impedir as suas ações resulta na promoção de um estado de alerta [15, 16]. Além disso,

também através da via antagonista do recetor de adenosina, os níveis cerebrais de serotonina podem aumentar. Durante o uso crônico de cafeína, a quantidade de serotonina mantém-se elevada contribuindo positivamente para o humor e sensação energética [17, 18].

Os recetores de dopamina e adenosina são co-localizados, interagindo funcionalmente entre si através de antagonismo competitivo. Assim, o consumo da cafeína estimula a via dopaminérgica, que por sua vez, desempenha um papel importante no sistema de comportamento motivado a recompensa, potenciando uma sensação prazerosa [19, 20]. Além disso, a dopamina controla aspetos críticos na função motora [21, 22]. Também é relatado o envolvimento da dopamina e, conseqüentemente da cafeína, sobre as emoções, cognição e memória [23, 22].

A cafeína também detém a capacidade de modular o sistema glutamatérgico em diferentes regiões do cérebro, sendo que a exposição a esta substância psicoativa faz aumentar a concentração de glutamato. À semelhança da dopamina, este neurotransmissor também desempenha um papel crítico na manutenção e plasticidade sináptica, contribuindo para a aprendizagem e memória [14, 24].

A neurotransmissão adrenérgica aumenta com o consumo de cafeína, uma vez que esta substância é uma precursora natural da adrenalina e noradrenalina [6]. Estas moléculas são responsáveis pela estimulação do sistema nervoso periférico, interferindo em várias funções biológicas: aumento da contratilidade do miocárdio, frequência cardíaca e débito cardíaco, promoção de broncodilatação, aumento da contração muscular induzida pelo aumento da concentração de cálcio intracelular, melhoria da capacidade de termorregulação, redução da dor, aumento da *performance* desportiva e aumento do metabolismo energético [25, 26]. Ademais, a cafeína através desta via de neurotransmissão juntamente com as atividades serotoninérgica e dopaminérgica, contribuem para a redução da fadiga geral [27]. Contudo, verificou-se que o uso prolongado da mesma dose de cafeína, resulta num decréscimo geral destes efeitos adrenérgicos [28].

O impacto global da cafeína no organismo humano faz desta substância uma das mais populares e procuradas do mundo. Evidências recentes demonstram que o vício em cafeína tem aumentado, especialmente pela capacidade de estimulação cognitiva [14]. O efeito psicostimulante da cafeína é de tal forma poderoso que só a expectativa de a ingerir, pode, por si só, melhorar o humor, mesmo que nenhuma quantidade seja consumida [29]. A sua capacidade de modulação das vias neurais revela efeito terapêutico no tratamento de várias doenças neurológicas e metabólicas, incluindo depressão, Alzheimer, Parkinson [30, 31], diabetes [32, 33], obesidade [34] e hipertensão, nomeadamente quando é consumida pelo café tradicional, que contém vários compostos bioativos com propriedades terapêuticas [35]. Ademais, estudos recentes mostram os benefícios pulmonares e de desenvolvimento neurológico da cafeína quando administrada em bebés prematuros [36], sendo este um dos cinco principais tratamentos mais prescritos em neonatologia [37]. Esta substância psicoativa também revela eficácia no âmbito desportivo. A suplementação com cafeína tornou-se cada vez mais popular como recurso ergogênico para atletas, especialmente pela modulação da via adrenérgica [38, 39].

Não obstante, o consumo exagerado de cafeína pode desenvolver efeitos indesejados ou deletérios, como insónias, ansiedade ou nervosismo, arritmias, problemas gastrointestinais, espasmos musculares, transtornos mentais, intoxicação e, no limite, morte. Estes efeitos são acentuados em

pessoas com doenças hepáticas e cardíacas, que podem morrer por ingerir cafeína em níveis bem abaixo do que normalmente é considerado tóxico [40].

Em indivíduos saudáveis, uma dose moderada de cafeína é de 3 a 6 mg/kg de massa corporal. Doses mínimas podem ser tão baixas quanto 2 mg/kg de massa corporal, sendo inexploradas doses a baixo desse limiar. Doses muito elevadas, que promovem a incidência dos efeitos indesejados, são entre 9 mg/kg de massa corporal, tornando-se fatal entre 150 a 200 mg/kg de massa corporal [11, 39].

Ainda que estes valores de referência sejam padronizados, os efeitos da cafeína no organismo humano variam de acordo com a sensibilidade individual à metilxantina, que pode variar de acordo com a predisposição genética de cada indivíduo, a idade, o gênero e os hábitos e condições de vida: ao contrário de um adulto, a atividade cortical cerebral é maior em prematuros revelando uma amplitude maior de resposta [37]; genericamente, os homens experimentam um aumento do efeito ergogênico em relação às mulheres [41]. Além disso, o tempo de semivida em fumadores é reduzido até 50%, aumentado em grávidas especialmente no terceiro trimestre e em recém-nascidos é prolongada a 8h e em prematuras a 100h, provavelmente devido à capacidade reduzida de metabolizá-la [11].

A forma de administrar a cafeína também parece influenciar a resposta do organismo, sendo que, a fonte de cafeína eleita provavelmente depende das necessidades pretendidas. Estudos têm sido desenvolvidos nesta área, a fim de criar soluções mais eficientes para as diferentes necessidades [39].

2.2 Oral films de cafeína

A via oral continua a ser a via de administração de substâncias eleita pela maioria dos consumidores devido à sua simplicidade e conveniência. Contudo, alguns indivíduos têm dificuldade em engolir comprimidos, cápsulas e até mesmo líquidos. O processo de deglutição envolve ações sincronizadas de vários nervos e músculos, supondo-se que uma deglutição segura é uma habilidade assegurada desde os 12 anos de idade. Associada à função da deglutição, está subjacente um processo de envelhecimento causado pela idade ou condições patológicas, levando a disfagia. Estas condições estão diretamente relacionadas com a adesão ao tratamento medicamentoso dos pacientes [42, 43]. Além disso, a biodisponibilidade dos medicamentos via oral varia muito, não apenas pelas suas propriedades físico-químicas, como também pelo metabolismo de primeira passagem causado pelo ambiente fisiológico do sistema gastrointestinal e a metabolização no fígado, levando a uma biodisponibilidade drasticamente reduzida [44].

OF surgiram como formulações inovadoras para refrescar o hálito, tendo recebido cada vez mais atenção pelos investigadores das indústrias farmacêuticas e nutracêuticas como um novo e promissor sistema de libertação de fármacos [44]. Em 2010, foram definidos pela *American Food and Drug Administration* (FDA) como incluindo ingredientes farmacêuticos ativos com propriedades flexíveis com rápida dissolução ou desintegração quando em contacto com a saliva [45].

O fabrico dos OF requer materiais adequados como excipiente capazes de transportar os princípios ativos de acordo com a carga e taxa de libertação desejadas. Os biomateriais mais comumente usados são os polímeros, pois são fáceis de manusear e existe maior facilidade em cumprir adequadamente as funcionalidades pré-projetadas para estes sistemas [46]. A existência de uma

variedade alargada de polímeros biocompatíveis e das tecnologias de produção tornam possível o desenvolvimento de OF com características peculiares e individualizadas [47, 48]. Além disso, componentes inativos podem ser incluídos para projetar o produto final de acordo com o perfil do alvo. Algumas dessas substâncias incluem plastificantes, adoçantes, aromatizantes, corantes e agentes estimuladores de saliva [45].

A versatilidade destes sistemas torna-os bastante apelativos em comparação com as formas de administração tradicionais. OF são uma forma farmacêutica com facilidade de administração, rápida dissolução e maior biodisponibilidade, reduzindo a dose necessária para atingir a ação terapêutica, o que pode contribuir também para uma redução dos efeitos colaterais. Além disso, a elevada vascularização da mucosa oral promove uma rápida absorção da substância ativa, antecipando o início de ação e da manifestação dos efeitos fisiológicos [44, 46].

Por todos os benefícios mencionados, esta nova tecnologia revela-se uma solução eficiente para a administração da cafeína, nomeadamente nos casos em que o objetivo são os efeitos que a substância provoca no organismo e não o ato de beber um café. Portanto, em ambientes militares e hospitalares, pilotagem aérea de longa duração, desportos de alta competição, entre outras situações onde é importante restaurar o estado de alerta e os desempenhos cognitivo e físico rapidamente, o OF acelera a taxa de libertação de cafeína no sangue por absorção através da mucosa bucal [49]. Além disso, durante o exercício moderado a intenso ocorre uma diminuição do fluxo sanguíneo esplâncnico e a taxa digestiva é reduzida, dificultando a absorção de cafeína pelas vias tradicionais no trato gastrointestinal [39].

Nestas situações, em que a dose ingerida é crucial para os efeitos desejados, o OF permite controlar a dosagem exata a ser libertada. Contrariamente, o teor de cafeína presente numa chávena de café é bastante variável e dependente de vários fatores, de entre os quais se salientam: a espécie, origem geográfica e forma como o café é cultivado, grau de torrefação e moagem dos grãos, método e tempo de preparação, relação da quantidade café/água, pressão e temperatura da água utilizada, fatores ambientais como armazenamento do café, altura acima do nível médio do mar e acesso à luz [50, 51]. Estudos demonstram, que de todas as formas de servir café, o expresso fornece a maior concentração de cafeína, mas é servido em quantidades volumétricas muito menores. Ainda assim, observou-se que o teor de cafeína varia consideravelmente no mesmo ponto de venda [52].

Fácil e rapidamente, sem necessidade de ingerir água ou mastigar, consegue-se controlar a quantidade de cafeína ingerida, e possivelmente de outros compostos inativos pertinentes, alcançando os efeitos desejados apenas com a colocação de um OF na boca, que se dissolve em segundos. Inclusive, ainda com base em resultados preliminares, estudos indicam que a presença de cafeína na mucosa oral pode estimular nervos sensoriais, induzindo respostas cerebrais, mesmo antes de qualquer absorção de cafeína [49].

A entrega de cafeína através destes sistemas de libertação representa um grande desafio para os investigadores [53]. Embora exista uma quantidade significativa de trabalhos científicos e patentes, a legislação atual sobre o desenvolvimento e produção de OF não é clara. A falta de orientações adequadas exige mais estudos para otimizar o desempenho dos OF e garantir os controlos de

qualidade e segurança [47]. Ademais, os efeitos fisiológicos da cafeína quando consumida por meio de OF ainda são uma temática com potencial de exploração [53].

2.3 Estado da arte

Apesar da investigação existente em estudos de caracterização e alguns farmacocinéticos, pouco se conhece sobre o efeito psicofisiológico dos OF [53]. Após a revisão de 298 publicações científicas, apenas 6 cumpriram os critérios de inclusão relativos ao impacto da cafeína administrada por OF, evidenciando a escassez literária nesta área [54].

A análise psicofisiológica sobre o efeito da cafeína no organismo integra dados da atividade cognitiva com a avaliação de índices fisiológicos ligados ao sistema nervoso autônomo, oferecendo uma visão que não é acessível pela avaliação de autorrelato [55, 56]. Estes parâmetros podem ser adquiridos através de metodologias robustas, como Ressonância Magnética Funcional, Magnetoencefalografia e Tomografia por Emissão de Positrões, contudo são técnicas caras e de difícil acesso [57]. Quanto às medidas psicofisiológicas periféricas, como eletrocardiograma, eletroencefalograma, eletromiografia, estabilometria, teste vestibular, pressão arterial, condutância da pele, atividade respiratória e rastreamento ocular, são metodologias relativamente simples de executar, minimamente ou não invasivas que apresentam resultados objetivos em tempo real [58, 59]. Estas vantagens inerentes a este tipo de estudos multidimensionais e multimodais, estimula o desenvolvimento de novos protocolos.

Neste sentido, um estudo recente validou, pela primeira vez, medidas psicofisiológicas para a caracterização de OF de cafeína, através de abordagens computacionais. Treze voluntários consumiram OF com cafeína e OF sem cafeína, em diferentes momentos e sem conhecer o produto, sendo monitorizadas a frequência cardíaca, frequência respiratória e atividade eletrodérmica (EDA). Em cada modalidade de sinal, o sinal completo foi dividido em segmentos de 5 min por análise. Para cada segmento foi extraída a energia de sinal, através de um processo de janelas retangulares deslizantes. Este parâmetro foi o escolhido como métrica discriminativa de sinal, ou seja, através da qual se avaliam as diferenças entre os dois grupos em estudo. Relativamente à análise do sinal cardíaco, os dados obtidos corroboram o efeito explanado na literatura – o consumo de cafeína estimula a atividade cardíaca, verificando-se níveis de energia mais altos quando os participantes consumiram o OF com cafeína. Contudo, os resultados mostraram a inexistência de picos acentuados, revelando atividade cardíaca controlada, devido ao padrão de liberação de cafeína dos OF. A análise da EDA revelou resultados muito semelhantes aos do sinal cardíaco, mas a precisão da discriminação entre o sinal afeto ao consumo de cafeína e o respetivo controlo não foi tão satisfatória. Por fim, o traçado do gráfico referente à atividade respiratória mostrou-se muito irregular e a precisão da discriminação não apresentou resultados de alta excelência. As conclusões desta investigação demonstram a possibilidade do desenvolvimento de uma nova metodologia para caracterizar o perfil de liberação de substâncias neuromoduladoras, como é o caso da cafeína. Ainda assim, novos estudos são exigidos, nomeadamente na aposta de métodos de processamento mais robustos. Além disso, a métrica utilizada pode não ser o biomarcador ideal para os sinais biomédicos em causa, uma vez que, a energia dos

sinais pode ser alterada por inúmeros eventos biológicos, que podem ter maior efeito do que o consumo do OF [57].

Posto isto, o presente projeto de investigação visa explorar esta metodologia inovadora através de técnicas computacionais mais robustas, incluindo a exploração de outras métricas. A oportunidade de realizar estudos com as vantagens inerentes a este novo protocolo pretende colmatar a lacuna científica existente nesta área.

Sinal Biomédico

Na literatura, a definição de sinal unidimensional (1D) consiste numa sequência ordenada de números que descrevem as tendências e variações de uma quantidade. Se o sinal for gerado num sistema biológico passa a designar-se por sinal biomédico [60]. Os sistemas biológicos podem ser descritos através de estruturas constituídas por nós e arestas, designadas redes – os nós representam os elementos do sistema e as arestas representam a relação entre esses elementos. Dependendo da escala das entidades biológicas em estudo, uma rede pode descrever sistemas, como o caso do organismo humano, onde os nós são os órgãos, tecidos ou células individuais que interagem entre si. A interconectividade e a função de cada elemento derivam de comportamentos biológicos e fisiológicos ao nível do sistema. Estes comportamentos são o resultado da atividade elétrica das células, que pode ser explorada através da aquisição desse sinal [61].

Assim sendo, explorar o sinal biomédico referente à atividade cardíaca, ECG, permite adquirir informação detalhada sobre a influência fisiológica da cafeína no organismo humano. Para tal, este capítulo centra-se na compreensão da estrutura e função do coração, bem como a geração e medição do sinal.

3.1 Coração

O coração é um órgão notavelmente complexo, cuja unidade estrutural e funcional designa-se por cardiomiócito – uma célula eletricamente ativa e mecanicamente contrátil [62]. A função primordial do coração é bombear sangue para todo o corpo [63], atuando como uma bomba dupla que suporta a circulação sanguínea em duas partes: transporte de sangue de e para os pulmões, assegurando a captação de oxigénio e a exalação de dióxido de carbono – circulação pulmonar, e o transporte de sangue de e para todas as células do organismo, assegurando a oxigenação de todos os tecidos – circulação sistémica [64]. Para tal, o coração serve-se de quatro reservatórios de sangue: duas aurículas, que atuam como câmaras recetoras, e dois ventrículos, que debitam o sangue para fora do coração [63]. A movimentação de sangue entre estas estruturas é conseguida por sucessivos ciclos de contração e relaxamento do músculo cardíaco, induzidos pela capacidade deste órgão gerar espontaneamente potenciais de ação de forma ritmada [64].

O sistema de condução cardíaco garante que o impulso elétrico é propagado ao longo de todo o coração, com uma dinâmica variável no espaço e no tempo. A condutividade elétrica das células é anisotrópica no eixo longitudinal do cardiomiócito, permitindo a rápida propagação elétrica nessa direção, e isotrópica no eixo transversal do cardiomiócito suportando uma propagação elétrica uniforme e mais lenta nesse plano. Esta propriedade física garante a coordenação e eficiência do músculo cardíaco. Embora o músculo cardíaco tenha autorritmicidade, a atividade cardíaca é modulada pelos sistemas endócrino e nervoso [65, 66].

A Figura 3.1 ilustra o sistema de condução cardíaco. O ciclo inicia-se quando o sinal é gerado numa pequena estrutura designada nó sinusal ou células *pacemaker*. Rapidamente, os potenciais de ação espalham-se pelos cardiomiócitos adjacentes, sendo conduzidos preferencialmente rumo ao nó auriculoventricular. Devido ao menor diâmetro destas fibras musculares, em comparação com as do nó sinusal, ocorre um atraso na propagação do sinal que permite a contração completa das aurículas antes do início da contração ventricular. Em seguida, os potenciais de ação são conduzidos em direção aos ventrículos através do feixe auriculoventricular, no qual a velocidade de propagação aumenta drasticamente. Os potenciais de ação passam pelos ramos esquerdo e direito do feixe alcançando as fibras de Purkinje, distribuídas por todo o miocárdio ventricular. Devido à distribuição do sistema de condução, a estimulação da contração ventricular começa no ápice em direção à base do coração, forçando o sangue a sair para cima através dos grandes vasos [64, 67].

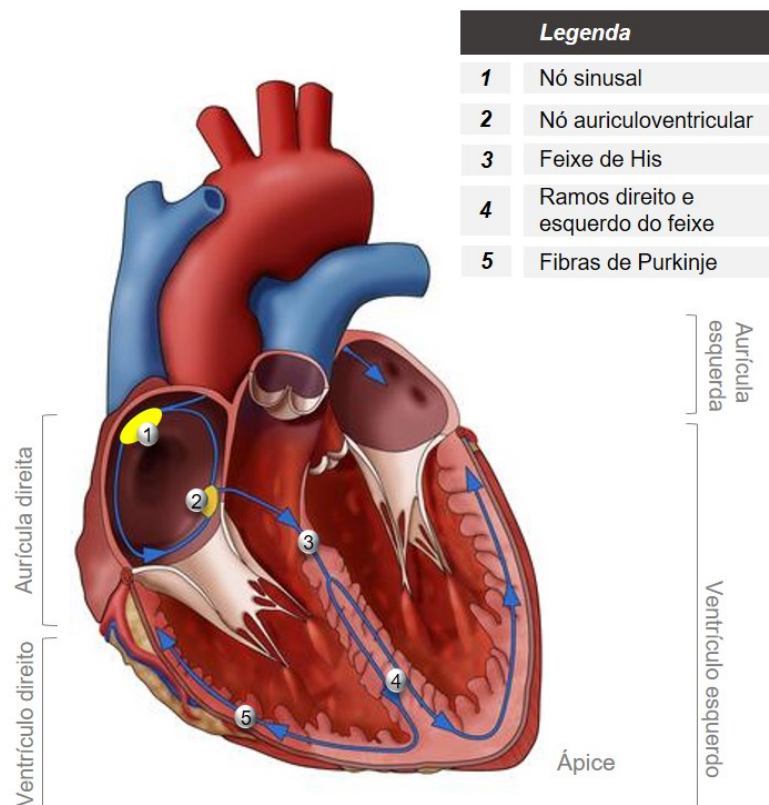


Figura 3.1 Sistema de condução do coração [Adaptado de [68]].

3.2 Eletrocardiograma

Os potenciais de ação que se propagam pelo miocárdio durante o ciclo cardíaco produzem correntes elétricas que podem ser mensuradas na superfície do corpo, através de elétrodos ligados a um eletrocardiógrafo. Os elétrodos colocados na pele registam a atividade elétrica do coração ao longo do tempo, num traçado designado por ECG (Figura 3.2). Cada deflexão no registo ECG indica um evento elétrico no coração, ao qual está correlacionado um evento mecânico posterior [67]. Desta forma, a eletrocardiografia é extremamente valiosa para o diagnóstico de uma série de anormalidades no ritmo cardíaco, principalmente por ser indolor, de fácil realização e não invasiva, proporcionando uma maior proximidade da medicina com a engenharia biomédica [69].




Figura 3.2 Traçado típico de ECG [Adaptado de [67]].

O número e posição dos elétrodos colocados na pele influênciam a visualização da atividade elétrica do coração, sendo que quanto maior o número de derivações utilizadas, mais informação o sinal biomédico fornece. É comum o eletrocardiógrafo servir-se de 12 derivações, onde cada uma mede e regista a atividade elétrica vista de diferentes ângulos [64, 70]. Neste caso, 10 elétrodos são colocados estrategicamente sobre o corpo humano: 4 elétrodos são colocados nas extremidades dos membros inferiores e superiores, sendo que, aquele conectado à perna direita atua como a terra do circuito elétrico protegendo os usuários do risco de choque elétrico (Figura 3.3a); e os restantes 6 elétrodos são posicionados no tórax (Figura 3.3b) [71]. Assim, a medição das derivações nas extremidades fornece a visão da atividade elétrica no plano vertical – *leads* frontais e, a medição das derivações no tórax fornece a visão da atividade elétrica no plano horizontal – *leads* precordiais [72].

Os *leads* frontais são identificados com os números romanos I, II, III, e consistem nos *leads* bipolares que formam o triângulo de Einthoven, um triângulo imaginário desenhado em redor do volume

do coração (Figura 3.3c). Estas três derivações mantêm entre si uma proporção matemática refletida na lei de Einthoven: $II=I+III$. Geometricamente, Emanuel Goldberger propôs as derivações associadas aos *leads* precordiais (Figura 3.3d). Estas são designadas por *leads* unipolares aumentadas aVR, aVL e aVF e, são referentes ao registo dos potenciais elétricos V1 a V6 em relação a um potencial de referência nulo (soma das tensões de RA, LA e LL é igual a zero) [71].

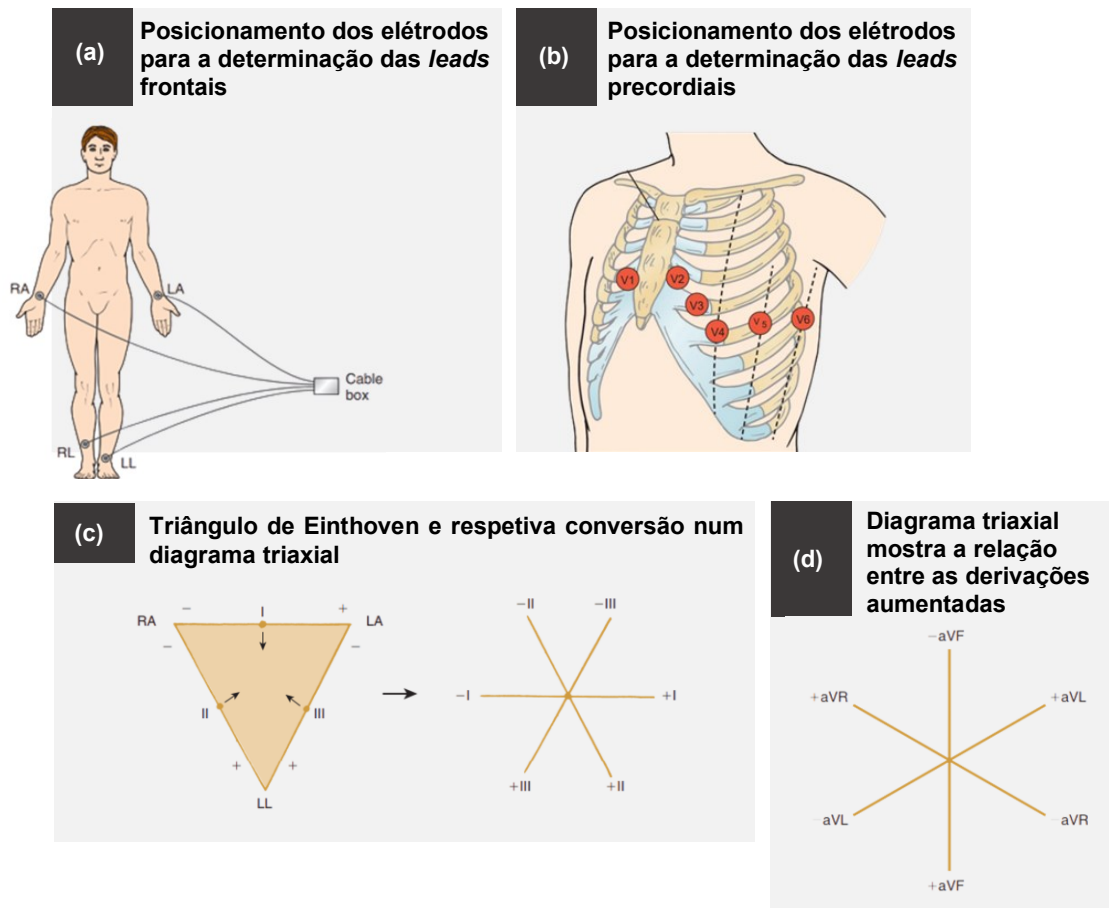


Figura 3.3 Princípios básicos na medição de ECG [Adaptado de [71]].

Processamento de Sinal

O Processamento de Sinal consiste num conjunto de técnicas que visam realçar, enfatizar e extrair características relevantes de um sinal, que de outra forma não seriam detetáveis [60]. A análise de ECG através de ferramentas tradicionais, como a Transformada de Fourier e extração de métricas lineares, estão associadas a pressupostos que podem induzir conclusões erróneas. Neste sentido, para maximizar a capacidade discriminativa do ECG tirou-se partido da sua natureza dinâmica com recurso a métodos e parâmetros não lineares.

4.1 Transformada Wavelet Discreta

Os sinais biomédicos tendem a exibir frequentemente oscilações rápidas em curtos intervalos de tempo ou variações lentas em intervalos longos, as quais acarretam informação crucial e determinante para as conclusões inferidas [73]. Em face disto, é conveniente recorrer a uma transformação que oferece uma resolução variável no plano tempo-frequência. Este é o caso da Transformada Wavelet (WT, do inglês “*Wavelet Transform*”), que oferece alta resolução temporal para as altas frequências e alta resolução espectral para as baixas frequências [74].

Ao contrário de outras transformadas, a WT serve-se de uma grande variedade de formas de onda que podem ser empregues desde que sejam satisfeitos os critérios matemáticos predefinidos [75]. A Tabela 4.1 reúne as famílias Wavelet mais comuns e importantes, bem como as suas propriedades.

Para a modulação das funções base, a WT serve-se da interação entre duas variáveis: a escala (α) – atua como um fator de compressão ($0 < \alpha < 1$) ou dilatação ($\alpha > 1$), sendo inversamente proporcional à frequência, pelo que fatores de escala pequenos são usados para analisar componentes de alta frequência, captando mudanças abruptas (visão detalhada), ao passo que, valores elevados determinam componentes de baixa frequência, captando mudanças lentas (visão global do sistema), e o parâmetro de translação (τ) – permite a translação da função wavelet de forma a cobrir todo o sinal no domínio do tempo, tendo associada a sua localização temporal [75, 76].

Tabela 4.1 Propriedades das famílias Wavelet mais comuns e importantes [77].

Propriedades	Famílias de Wavelet						
	Haar	Db	Sym	Coif	Bior	rBio	Meyr
Simétrica	X				X	X	X
Assimétrica		X					
Perto de ser simétrica			X	X			
Regularidade arbitrária		X	X	X	X	X	
Regularidade infinita							X
Número arbitrário de momentos zero		X	X	X	X	X	
Análise Ortogonal	X	X	X	X			X
Análise Biotogonal					X	X	
Transformada contínua	X	X	X	X	X	X	X
Transformada discreta	X	X	X	X	X	X	X
Algoritmo rápido		X	X	X	X	X	
Reconstrução exata	X	X	X	X	X	X	X

Db=Daubechies; Sym=Symlet; Coif=Coiflet; Bior=Biotogonal; rBio=Biotogonal Reversa; Meyr=Meyer

Entre as várias representações, a Transformada Wavelet Discreta (DWT, do inglês “*Discrete Wavelet Transform*”) é a mais utilizada devido à sua capacidade de adaptação a diferentes problemas e ao elevado desempenho computacional. Além disso, a teoria evidencia que a versão discreta da análise pela WT é suficiente para descrever o sinal [78]. A DWT consiste numa análise multiresolução, na qual a ideia fundamental é representar a função como um limite de sucessivas aproximações, cada qual como uma versão melhorada da função. Estas sucessivas aproximações correspondem a diferentes níveis de resolução (escalas), sendo este parâmetro uma descrição qualitativa associada à frequência [79]. O processo consiste na aplicação de *dyadic grid*, isto é, uma hierarquia onde uma célula é recursivamente dividida em dois no próximo nível [80]. Para esta decomposição sucessiva de componentes, a DWT serve-se da função escala $\varphi[n]$ e da função wavelet $\psi[n]$, ambas representadas pelas seguintes equações:

$$\varphi[n] = \sum_k h[k] \cdot \varphi[2n - k] \quad 4.1$$

$$\psi[n] = \sum_k g[k] \cdot \psi[2n - k] \quad 4.2$$

onde, k é o parâmetro de translação discreta, $h[k]$ e $g[k]$ são, respetivamente, as respostas de impulso aos filtros passa-baixo e passa-alto e definem o tipo de Wavelet utilizada [73]. Este processo de filtragem é a essência da decomposição wavelet em j níveis, na qual o filtro passa-baixo está relacionado com os coeficientes de aproximação DWT_{approx}^{φ} e o passa-alto com os coeficientes de detalhe DWT_{det}^{ψ} . Matematicamente, os coeficientes são expressos da seguinte forma:

$$DWT_{aprox,j}^{\varphi}[k] = \sum_{n=0}^{\frac{N}{2^{j-1}}} \cdot DWT_{aprox,j-1}^{\varphi}[n] \cdot h[2k - n] \quad 4.3$$

$$DWT_{det,j}^{\psi}[k] = \sum_{n=0}^{\frac{N}{2^{j-1}}} \cdot DWT_{det,j-1}^{\psi}[n] \cdot g[2k - n] \quad 4.4$$

Em cada nível o sinal é subamostrado, pelo que o nível j tem metade da largura de banda do nível anterior $j-1$, portanto esta nova versão do sinal tem metade da resolução temporal (devido à subamostragem) com o dobro da escala (devido à filtragem), permitindo a análise do sinal em diferentes bandas de frequência com diferentes resoluções. Este processo, designado de Codificação Sub-banda, pode ser repetido J vezes, até que não seja possível diminuir mais a resolução do sinal [73, 81]. Na prática, seleciona-se um número satisfatório de níveis consoante a natureza do sinal e a faixa de frequências desejável, que pode ser determinado pela fórmula matemática:

$$J = \log_2(N) \quad 4.5$$

na qual, J representa o número máximo de níveis de decomposição e N o número de amostras [81]. A Figura 4.1 resume a aplicação do método.

Por fim, o sinal original pode ser reconstruído a partir dos coeficientes de aproximação do último nível de decomposição e dos coeficientes de detalhes de todos os níveis [75].

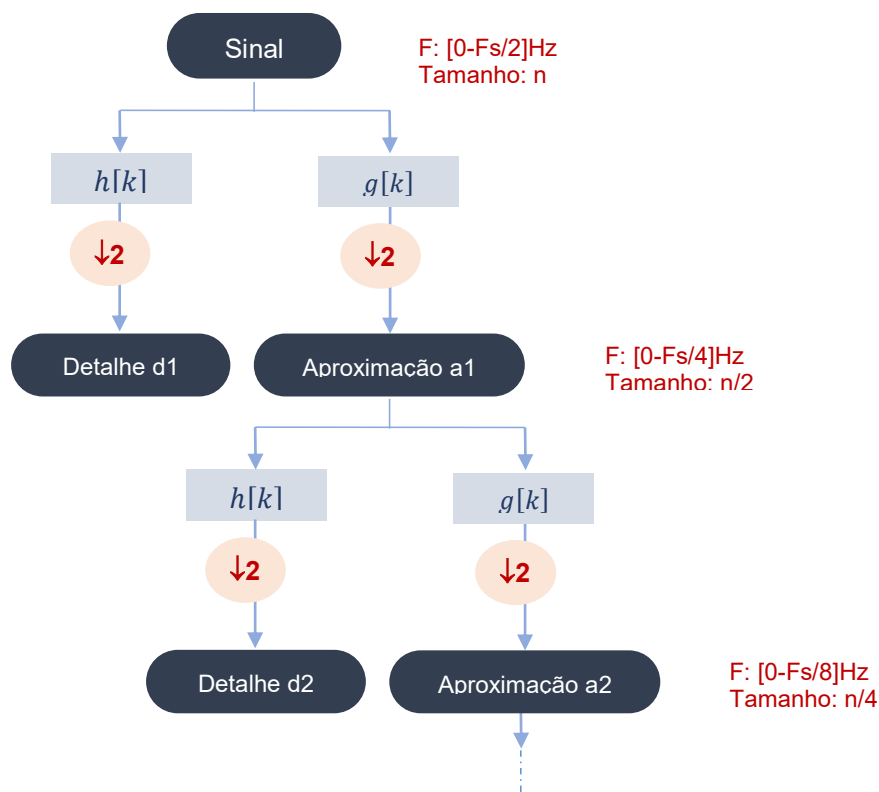


Figura 4.1 Aplicação da DWT [Adaptado de [73]].

4.2 Análise não linear

A evidência demonstra que a análise de sinais ECG recorrendo a técnicas não lineares melhora o processo de extração e classificação de características, sendo que cada medida reflete a complexidade com diferentes abordagens [82]. Embora um grande número de modelos não lineares tenha sido proposto nos últimos anos, esta dissertação cinge-se aos mais comuns para uma primeira abordagem.

4.2.1 Teoria do Caos

A correta análise da evolução de sistemas dinâmicos implica a representação espacial dos seus estados ao longo do tempo, na qual um sistema definido por n variáveis pode ser representado por um ponto no espaço n -dimensional, que represente o valor de todas as suas variáveis num dado instante [83]. Os estados consecutivos representados neste espaço de fase definem trajetórias, que quando observadas por longos períodos de tempo, tendem a convergir para uma estrutura geométrica específica, independentemente do ponto de partida, designada atrator [84]. Assim, o sistema evolui no sentido de comportamentos extremamente irregulares, complexos e não periódicos – designados comportamentos caóticos – nos quais, embora não haja previsibilidade, convergem para um comportamento estruturalmente estável [85].

A evolução da dinâmica do sistema é tipicamente investigada recorrendo à extração de métricas não lineares a partir do atrator, que analisam conceitos relacionados com a estabilidade, variabilidade, complexidade e similaridade [86]. A precisão da reconstrução do atrator é criticamente importante para a aplicação desses métodos, como tal devem ser considerados dois parâmetros: o atraso (τ) e a dimensão de incorporação (d). Assim, a reconstrução do atrator é conseguida através de uma única variável de estado ($x(i)$), através da fórmula [87]:

$$x(i) = (x(i), x(i + \tau), x(i + 2\tau), \dots, x(i + (d - 1)\tau)) \quad 4.6$$

4.2.1.1 Expoente de Lyapunov

As trajetórias num atrator caótico evoluem particularmente de duas formas: expansão, onde as trajetórias dos pontos considerados divergem exponencialmente em relação às condições iniciais (pontos próximos no espaço de fase), e convergência, na qual as trajetórias convergem entre si ao longo do tempo [88]. Do ponto de vista dinâmico, o expoente de Lyapunov (λ) mede a taxa média de expansão e convergência de trajetórias no espaço de fase, caracterizando assim a previsibilidade do sistema dinâmico [89, 90]. Para um espaço com dimensão N , existem N expoentes de Lyapunov. Contudo, é comum determinar apenas o maior expoente de Lyapunov por ser mais simples de calcular e porque fornece uma visão mais abrangente da dinâmica do sistema [91]. Se o maior expoente de Lyapunov for positivo então o atrator é caótico, refletindo a magnitude do expoente a escala de tempo na qual esse comportamento é visível [90].

Esta medida pode ser estimada através da seguinte equação matemática:

$$\lambda(i) = \frac{1}{(K_{\max} - K_{\min} + 1)dt} \sum_{K=K_{\min}}^{K_{\max}} \frac{1}{K} \cdot \ln \frac{\|Y_{i+K} - Y_{i^*+K}\|}{\|Y_i - Y_{i^*}\|} \quad 4.7$$

na qual, K_{\min} e K_{\max} representam o intervalo de expansão, dt é o tempo de amostragem e Y_i representa o valor da reconstrução do sinal para a dimensão e atraso considerados [92].

4.2.1.2 Expoente de Hurst

O expoente de Hurst (H) é uma medida adimensional utilizada para avaliar a auto-similaridade e as propriedades de correlação de longo alcance das séries temporais [93]. O cálculo deste expoente é definido em termos do comportamento assintótico do intervalo redimensionado (uma medida estatística da variabilidade de uma série temporal) em função do período da série temporal, da seguinte forma:

$$H = \frac{\log\left(\frac{R}{S}\right)}{\log(T)} \quad 4.8$$

onde, T é a duração da amostra, R/S é o valor correspondente ao intervalo redimensionado, sendo R a diferença entre o desvio máximo e mínimo da média e S representa o desvio padrão [94, 95].

Quando $H=0,5$ não se verifica correlação na série temporal (comportamento aleatório). Se $0 < H < 0,5$ a série temporal apresenta alternância de longo prazo, isto é, um valor alto provavelmente será seguido de um baixo e vice-versa. Por outro lado, se $0,5 < H < 1$ então a série temporal é definida como autocorrelação positiva de longo prazo. No limite teórico, quando $H=1$ a série temporal apresenta uma correlação perfeita [94, 96].

4.2.2 Dimensão Fractal

Fractal é um modelo matemático utilizado para descrever processos aleatórios invariantes de escala, sendo caracterizado pelas suas dimensões fracionárias [97]. Esta característica única permite reconhecer padrões geométricos semelhantes que se repetem infinitas vezes em qualquer escala de ampliação [98]. Existem vários métodos para estimar a dimensão fractal. Entre eles, o algoritmo de Higuchi é conhecido por ser mais preciso e eficiente, visando quantificar a auto-similaridade e complexidade do sinal [60].

A dimensão fractal de Higuchi (HFD, do inglês "*Higuchi Fractal Dimension*") baseia-se numa medida de comprimento $L(k)$ da curva que representa a série temporal. Se escalar como $L(k) \sim k^{-Df}$, acredita-se que a curva mostre a dimensão fractal Df . Para tal, a partir de uma dada série temporal o algoritmo constrói k novas séries temporais, $x_{m,k} = x(m), x(m+k), x(m+2k), \dots, x\left(m + \text{int}\left(\frac{N-m}{k}\right)k\right)$,

onde m representa o valor inicial do tempo, k é o tempo de intervalo e $\text{int}(r)$ representa a parte inteira de um número real r . O comprimento de $L_m(k)$ de cada curva é então calculado através da expressão:

$$L_m(k) = \frac{\sum_{i=1}^{\text{int}((N-m)/k)} |x(m + i \cdot k) - x(m + (i + 1)k)|}{\text{int}\left(\frac{N-m}{k}\right)k} \quad 4.9$$

onde, N é o número total de amostras. Este processo é repetido para cada k , de 1 até k_{max} , sendo k_{max} determinado experimentalmente. Por fim, o valor Df é calculado através do método do melhor ajuste linear dos mínimos quadrados, sendo o valor $Df_{Higuchi}$ o declive da regressão linear entre $\ln(L_m(k))$ e $\ln(1/k)$ [99, 100].

4.2.3 Energia e Entropia

Um sinal é uma variação de energia que carrega informação, pelo que estudar as características energéticas do sinal é das técnicas mais comuns em processamento de sinal. Neste sentido, a energia pode ser vista como uma medida da intensidade do sinal e pode ser obtida através do cálculo:

$$E_g = \sum_i |g(n)|^2 \quad 4.10$$

onde, g representa o sinal [101, 102].

O conceito mais importante na teoria da informação é a entropia de Shannon, que descreve a quantidade de informação contida nos dados. Esta medida quantifica o nível de desordem e incerteza num sistema [103]. A entropia avalia a previsibilidade dos valores de amplitude futuros com base na distribuição de probabilidade dos valores de amplitude observados anteriormente, ou seja, a informação presente pode ser explicada pelo histórico de informação passado. Nesta linha de raciocínio, valores elevados de entropia estão associados a dados incertos (muita informação) e mais difíceis de prever. Em contrapartida, se todas as observações são unânimes, não há incerteza e o valor da entropia é nulo [104, 105, 106].

A entropia de Shannon pode ser estimada pela equação:

$$E_{shanon, g} = - \sum_i |g(n)|^2 \cdot \log[|g(n)|^2] \quad 4.11$$

onde, g representa o sinal [106].

Métodos de Classificação

As novas tecnologias estão a transformar a medicina e grande parte dessa revolução tem por base a Inteligência Artificial. A maior parte do trabalho desenvolvido nesta área é através de *Machine Learning*, uma técnica que fornece aos computadores a capacidade de aprenderem sem serem explicitamente programados [107]. A forma mais complexa de *Machine Learning* envolve *Deep Learning*, uma abordagem promissora de sucesso para tarefas discriminativas e generativas, que é bem-sucedida na implementação e desempenho, [108] alcançando precisões de reconhecimento nunca antes alcançadas. Esta tecnologia é de tal forma avançada que consegue ultrapassar as barreiras do conhecimento humano, gerando resultados difíceis ou impossíveis de interpretar [109].

Este capítulo explana os algoritmos de classificação de sinal explorados nesta dissertação.

5.1 X-ROC

O X-ROC (do inglês “*Receiver Operating Characteristic*”) é um classificador binário que utiliza a informação de dois grupos para determinar o limiar entre as médias das suas distribuições (Figura 5.1a), sendo o processo de classificação aplicado segundo validação cruzada *leave-one-out*. Este limiar está associado ao valor de corte ideal que permite a discriminação das categorias dicotómicas [110]. Para avaliar o desempenho do classificador recorre-se à curva ROC (Figura 5.2b), uma representação gráfica do *trade-off* entre a sensibilidade (probabilidade de verdadeiro-positivo) e a especificidade (probabilidade de falso-positivo). A área da curva ROC é uma medida efetiva da precisão do classificador, onde quanto maior a área melhor é a *performance* do classificador [111].

O método ideal teria sensibilidade e especificidade iguais a 1, contudo como estes parâmetros são inversamente proporcionais o objetivo é encontrar o melhor compromisso entre eles. Para tal deve-se considerar que, quanto mais rigorosos forem os critérios para determinar um resultado positivo mais pontos na curva se deslocam para baixo e para esquerda. Em contraste, se aplicarmos critérios mais flexíveis, os pontos na curva movem-se para cima e para a direita [112].

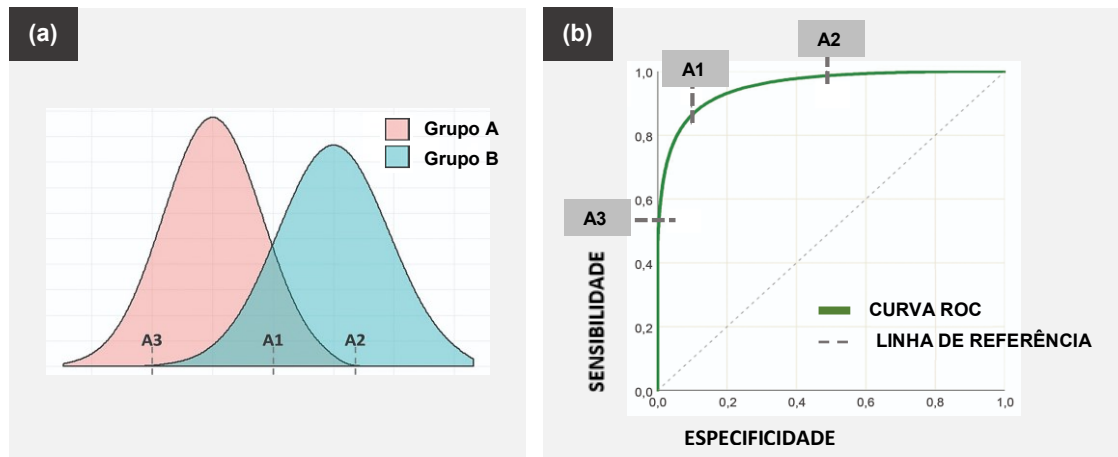


Figura 5.1 Teste hipotético que visa classificar dois grupos: A e B. (a) Representação das curvas de distribuição e (b) respectiva Curva ROC. O Ponto A1 representa o valor de corte associado a maior sensibilidade e especificidade. O Ponto A2 representa o valor de corte com a máxima sensibilidade (ausência de falsos positivos). O Ponto A3 é o valor de corte associado a máxima especificidade, abaixo do qual não se verificam falsos negativos [Adaptado de [113]].

5.2 Árvore de Decisão

O algoritmo Árvore de Decisão é um modelo simples e amplamente utilizado para classificar sinais biomédicos, nomeadamente pela fácil interpretabilidade. Este método constrói uma estrutura gráfica em forma de árvore invertida, a partir dos dados em análise e de uma série de decisões lógicas sobre eles [114], conforme ilustra a Figura 5.2. O ponto de partida deste fluxograma inicia-se com o nó raiz, no qual todos os dados do estudo são introduzidos. Uma sequência de testes binários é aplicada gerando os nós de decisão, ligados entre si através dos ramos, os quais representam os resultados do teste. Durante este processo, é crucial escolher de entre os atributos disponíveis aqueles que maximizam o ganho de informação em cada etapa. Em cada iteração, o algoritmo escolhe a melhor forma de dividir o conjunto através de uma função discreta de valores dos atributos de entrada. O processo termina quando não há mais atributos para testar e, neste ponto, o programa retorna os rótulos de classe designados por nó folha [115].

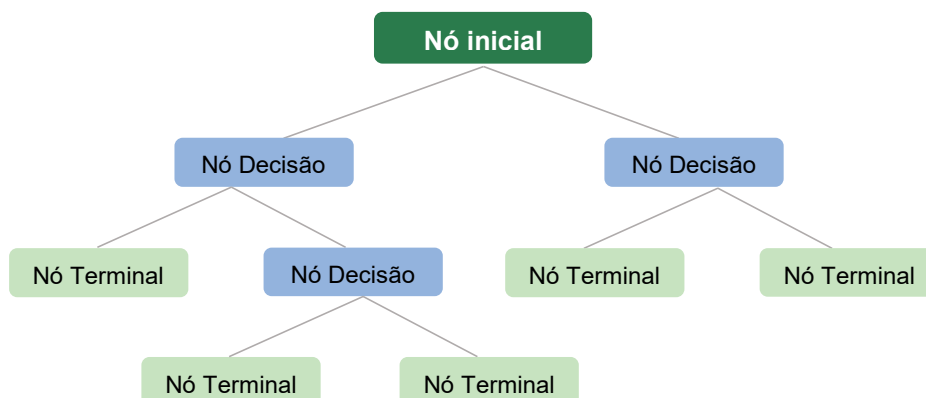


Figura 5.2 Ilustração típica do algoritmo Árvore de Decisão [Adaptado de [114]].

É possível ajustar a flexibilidade do modelo com a configuração do número máximo de iterações. Neste sentido, existem três tipos de classificadores: (1) *Coarse Tree* que se serve de poucas folhas fazendo uma distinção mais grosseira entre as classes – baixa flexibilidade com 4 divisões máximas, (2) *Medium Tree* que utilizava um número médio de folhas – média flexibilidade com 20 divisões máximas, e (3) *Fine Tree* que recorre a muitas folhas conseguindo uma distinção muito fina entre as classes – elevada flexibilidade com 100 divisões máximas [77].

5.3 Análise Discriminante

A análise discriminante é uma técnica de reconhecimento de padrões, que visa alcançar a melhor discriminação de dados em grupos previamente rotulados. Para avaliar as relações entre diferentes grupos, um método adequado deve focar-se na variabilidade entre grupos, enquanto negligência a variação dentro do grupo. Por vezes a predefinição não é suficientemente precisa e o método realoca as amostras noutros grupos. Além disso, a análise discriminante permite que novas observações multivariadas sejam alocadas aos grupos pré-definidos [116, 117].

Embora seja fácil de implementar, a análise discriminante apresenta restrições que impedem a sua aplicação: (1) o número de variáveis tem de ser menor do que o número de observações, e (2) as correlações entre variáveis dificultam o processo discriminatório [117].




Figura 5.3 Processo de classificação por Análise Discriminante [Adaptado de [118]].

5.4 Regressão Logística

A regressão logística é essencialmente um algoritmo de classificação, que descreve a relação entre uma variável dependente dicotómica e uma ou mais variáveis independentes categóricas [119]. Este modelo de classificação binária classifica a amostra em duas classes, podendo estender-se para um número arbitrário de classes, passando a designar-se regressão logística multinomial [120].

O modelo de regressão logística baseia-se no conceito de *odds* – a probabilidade de um evento ocorrer dividida pela probabilidade de um evento não ocorrer [120]. Desta forma, este método estima a probabilidade p de um dado pertencer a uma determinada classe, ajustando estes valores a uma curva

logística, a qual representa a relação exponencial entre as variáveis (Figura 5.4). Esta função, em forma de sigmoide, é representada segundo o eixo das coordenadas como a probabilidade de uma dada classificação (os valores são mapeados no intervalo entre 0 e 1) e no eixo das abcissas como o valor da variável independente x [121]. Matematicamente, o modelo da regressão logística é estimado pela função logística:

$$y = \frac{1}{1 + e^{-x}} = \frac{1}{1 + e^{-(\alpha + \beta x)}} \quad 5.1$$

na qual, os coeficientes da regressão são representados pelos símbolos α e β , que determinam o ponto de interseção logístico e a inclinação, respetivamente [121].




Figura 5.4 Curva logística quando $\alpha=0$ e $\beta=1$. Quando a resposta y consiste numa variável binária (dicotómica) e x é numérica, a função logística ajusta uma curva representativa da relação entre estas variáveis $y=f(x)$ [Fonte [121]].

5.5 Naïve Bayes

O classificador Naïve Bayes pertence à família de classificadores probabilísticos e é baseado no teorema de Bayes, que assume que cada característica contribuiu de forma independente e igual para a classe alvo, não interagindo com as demais. Por outras palavras, a forte suposição subjacente a este algoritmo da independência dos recursos ou atributos envolvidos na previsão, contribui para a mesma probabilidade de uma amostra pertencer a uma determinada classe [122, 123].

Este algoritmo processa o conjunto de dados de treino para calcular as probabilidades de classe y_i e as probabilidades condicionais, que definem a frequência de cada valor de característica X para um determinado valor de classe dividido pela frequência de instâncias com esse valor de classe [123]. Para fins de explicação, suponha-se que o classificador é aplicado a amostras, de modo que cada amostra tem três características (X_1, X_2, X_3). Naïve Bayes realiza a tarefa de classificação binária para atribuir um único rotulo y_1 ou y_2 a cada amostra, com base nos valores de característica. Para tal, o algoritmo processa os dados de treino para aproximar a probabilidade de cada classe ao conjunto de características, da seguinte forma [123, 124]:

$$P(y_i|X_1, X_2, X_3) = \frac{P(X_1|y_i) P(X_2|y_i) P(X_3|y_i) P(y_i)}{P(X_1) P(X_2) P(X_3)} \quad 5.2$$

Finalmente, o algoritmo estima a probabilidade de uma nova amostra pertencer a uma classe existente e, aquela com maior valor de probabilidade, será a classe à qual os dados de entrada pertencem. Este conceito é designado de regra de decisão máxima à posteriori, ou seja, a escolha da hipótese mais provável, e expressa-se matematicamente como [123, 125]:

$$y = \operatorname{argmax}_{y_i} P(X_1|y_i) P(X_2|y_i) P(X_3|y_i) P(y_i) \quad 5.3$$

A metodologia pode ser executada pelo classificador *Gaussian Naive Bayes* que considera que as classes seguem uma distribuição normal, não se podendo ajustar nenhum parâmetro para controlar a flexibilidade do modelo [77]. O classificador é simples de implementar, computacionalmente rápido e altamente escalável. Requer um pequeno número de dados para ser treinado e pode lidar com grande volume de dados de alta dimensionalidade [126].

5.6 Support Vector Machines

Support Vector Machines (SVM) é um algoritmo de classificação de hiperplano de separação. Há um hiperplano no espaço multidimensional que classifica corretamente todas as instâncias de treino, de acordo com as classes pré-definidas [127].

No contexto de SVM, a tarefa aparentemente intratável de mapear dados não linearmente separáveis num espaço de dimensão elevada é alcançada de forma eficiente executando o mapeamento através da função de Kernel [128]. SVM visa encontrar um mapeamento que minimize o número de dados de treino mal classificadas. Intuitivamente, o algoritmo averigua os dados mais problemáticos nesse sentido, ou seja, os dados que estão mais próximos dos limites da classe e, portanto, com maior probabilidade de serem classificados incorretamente. Estes pontos formam os vetores de suporte que dão nome à abordagem [129]. O conjunto de vetores de suporte permite definir o hiperplano de margem máxima, ou seja, aquele que oferece a maior separação entre as classes, não chegando mais perto do que o necessário (Figura 5.5). A partir deste ponto, todas as outras instâncias de treino são irrelevantes, podendo ser excluídas sem alterar a posição e a orientação do hiperplano [127]. Neste momento, novos dados podem ser introduzidos e atribuídos automaticamente a uma das classes conforme a sua posição em relação ao hiperplano [130].

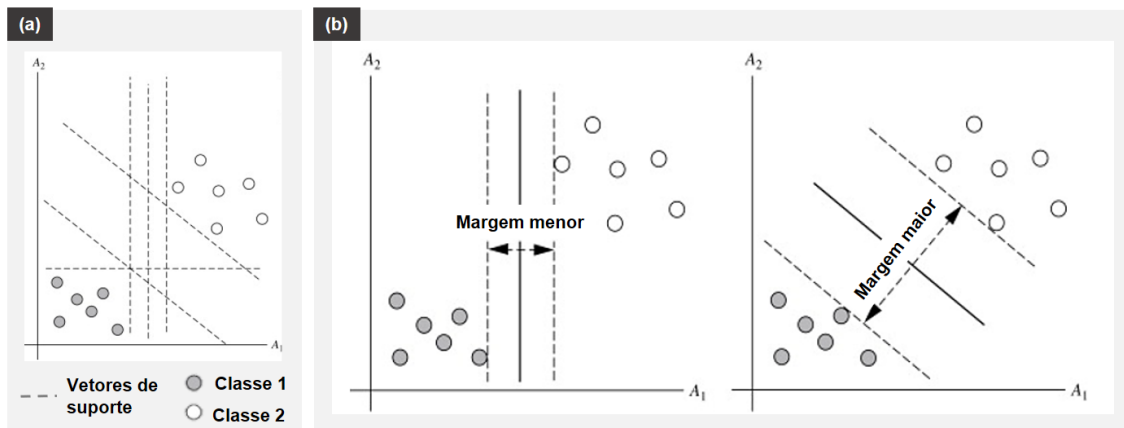


Figura 5.5 Hiperplanos de separação. (a) Em geral, existe um número infinito de hiperplanos de separação possíveis, sugerindo *overfitting*. SVM procura encontrar o hiperplano ideal que terá o mínimo de erro de classificação. Como tal, consideremos (b) que apresenta dois hiperplanos possíveis e as respectivas margens associadas. Verificamos que ambos classificam corretamente todas as instâncias, no entanto, para classificação de dados futuros é conveniente utilizar o modelo de margem maior por ter maior precisão – hiperplano marginal máximo [Adaptado de [130]].

Matematicamente, a forma como a distinção das classes é executada origina diferentes tipos de classificadores: (1) *Linear SVM* – faz uma separação linear simples entre as classes, (2) *Quadratic SVM*, (3) *Cubic SVM*, (4) *Fine Gaussian SVM* - faz distinções finamente detalhadas entre classes, assumindo a distribuição normal com a escala de Kernel definida como $\sqrt{\text{num_preditores}}/4$, (5) *Medium Gaussian SVM* - ($\sqrt{\text{num_preditores}}$) e (6) *Coarse Gaussian SVM* - faz distinções grosseiras entre classes, assumindo a distribuição normal ($\sqrt{\text{num_preditores}}*4$) [77].

5.7 K-Nearest-Neighbors

O classificador *K-Nearest-Neighbors* (KNN) baseia-se na suposição de que determinada instância num conjunto de dados existirá em estreita proximidade com outras instâncias que compartilham características semelhantes [131]. Se as instâncias forem associadas a um rótulo de classificação, a classe de uma nova instância poderá ser determinada observando as classes das suas instâncias vizinhas [132]. A vantagem da classificação pelo KNN é a sua simplicidade, estando o algoritmo sujeito à influência de apenas dois parâmetros: (1) o número de k-vizinhos a analisar que, normalmente, é determinado para minimizar o erro da classificação como \sqrt{N} , onde N é o número total de pontos com conjunto de dados de treino, ou por procedimentos de validação cruzada – pequenos valores de k selecionam os pontos de treino mais próximos, contudo esta estimativa terá associada grandes flutuações estatísticas, e valores de k elevados reduzem erros estatísticos, mas permitem que pontos distantes influenciem a classificação, podendo promover a suavização de detalhes importantes sobre a distribuição de classes [133, 134], e (2) a função utilizada para calcular as distâncias entre a amostra e os seus vizinhos, podendo esta última tomar diversas formas, sendo as mais comuns a distância euclidiana, a distância de Mahalanobis e a distância de quarteirão [131, 135].

De uma forma elementar, cada ponto do conjunto de dados de treino é caracterizado por um conjunto de variáveis, pelo que, conceitualmente, é mapeado num espaço de alta dimensão, onde cada eixo corresponde a uma variável individual [133]. Quando $k=1$, o algoritmo agrupa a amostra considerada ao seu vizinho mais próximo. Quando $k>1$, a amostra é comparada com os seus k -vizinhos e associada à classe de menor distância média, isto é, a classe com maior número de vizinhos nas proximidades [131]. A Figura 5.6 ilustra o processo de classificação KNN.

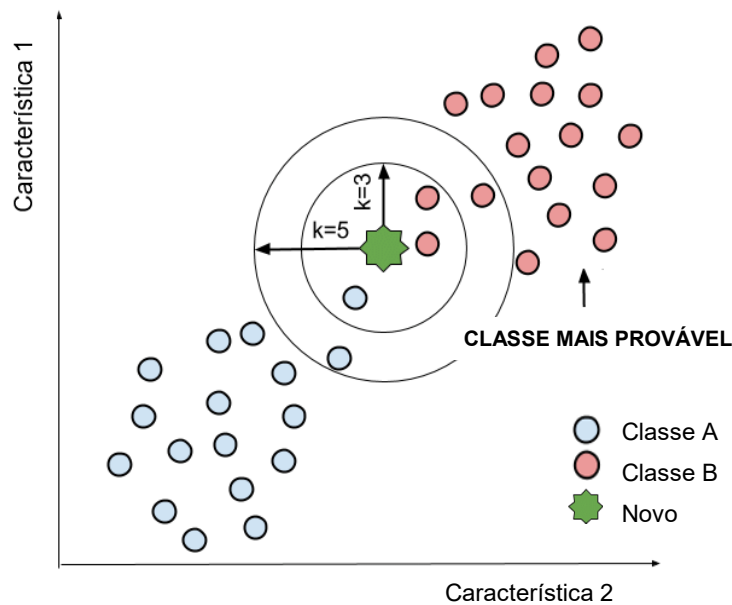


Figura 5.6 Classificação por KNN [Adaptado de [136]].

É possível ajustar a flexibilidade do modelo de duas formas: configurando o número de pontos vizinhos (Tabela 5.1) e alterando a métrica avaliativa da distância (Tabela 5.2) [77]:

Tabela 5.1 Modelo de classificação ajustando o número de pontos vizinhos [77].

Classificador	Distinção entre classes	Vizinhos
<i>Fine KNN</i>	Separadas finamente com elevado nível de detalhe	1
<i>Medium KNN</i>	Separação média	10
<i>Coarse KNN</i>	Separação grosseira	100

Tabela 5.2 Modelo de classificação ajustando a métrica avaliativa da distância [77].

Classificador	Distinção entre classes	Vizinhos	Métrica avaliativa da distância
<i>Cosine KNN</i>	Separação média	10	Cosseno
<i>Cubic KNNc</i>	Separação média	10	Cúbica
<i>Weighted KNN</i>	Separação média	10	Ponderada - atribui a cada distância um peso

5.8 Aproximação de Kernel

A descoberta de relações não lineares entre padrões de entrada e a capacidade de trabalhar com dados heterogêneos sempre foram duas características desejáveis em *Machine Learning*. A este respeito, é necessário enfatizar que o método de Kernel não apenas fornece esta possibilidade de forma natural, como também é fundamentado em conceitos matemáticos robustos e intuitivos, solucionando problemas de classificação complicados [137].

Essencialmente, o método visa tratar dados que não são linearmente separáveis por métodos de classificação clássicos, regendo-se por técnicas de transformação que mapeiam esse conjunto de dados de entrada num espaço de alta dimensão (Figura 5.7) [138]. Em seguida, estes dados são ajustados a um modelo linear para o processo de classificação, salientando-se os algoritmos SVM e regressão logística. Assim, diferentes funções de Kernel produzem diferentes transformações do espaço de atributos e, conseqüentemente, métodos de classificação distintos [139]. A transformação deve ser efetuada com cuidado, para oferecer um modelo linear confiável no espaço de recursos a que corresponde uma solução não linear no espaço de dados original [140]. Neste contexto, é importante considerar que a escolha de uma aproximação de Kernel inadequada pode comprometer o desempenho do método de classificação, de tal forma que, o resultado pode ser ainda pior do que o do seu equivalente linear [141].




Figura 5.7 Método de Kernel. Aplicando a função de Kernel ϕ a um espaço de baixa dimensão, consegue-se separar linearmente as classes num espaço de atributos de alta dimensão [Adaptado de [142]].

5.9 Ensemble Learning

Ensemble Learning é uma abordagem baseada em múltiplos modelos de *Machine Learning*, que são gerados e combinados estrategicamente de forma a otimizar problemas de classificação. A ideia por detrás deste conceito é que duas mentes pensam melhor do que uma, logo os resultados serão tanto melhores quanto maior for a diversidade entre os modelos. Ou seja, a combinação de informação de múltiplas fontes impulsiona a tomada de decisões estratégicas [143].

O conceito básico deste método consiste em treinar um conjunto de dados de entrada recorrendo a vários algoritmos de classificação e, combinar as suas previsões numa única saída que deve ter em média melhor desempenho do que qualquer outro membro do conjunto [144]. Por outras palavras, o classificador *Ensemble Learning* combina resultados de vários modelos de classificação num único modelo robusto de alta qualidade [145]. Existem várias propostas para a implementação deste método, sendo comum a todas elas três aspetos fundamentais: (1) como treinar cada membro de classificação, (2) como combinar as previsões obtidas em cada membro numa única saída – métodos de combinação, e (3) qual o fator crítico que determina o sucesso do modelo – diversidade do conjunto [144, 146].

As abordagens mais adotadas são designadas de *Bagging* e *Boosting* [146]. Relativamente ao primeiro método, a partir de um conjunto de dados são gerados diferentes subconjuntos de treino, sendo cada um treinado, em paralelo, por diferentes classificadores conforme ilustrado na Figura 5.8a. Cada subconjunto contempla o mesmo número de instâncias que o conjunto de dados de entrada, pelo que algumas das instâncias podem repetir-se no mesmo subconjunto ou até nem serem selecionadas. O algoritmo *Bagging* é geralmente utilizado quando o sistema é instável, isto é, quando para qualquer variação no conjunto de dados de entrada verifica-se uma grande variação na saída [144].

O método de *Boosting* utiliza a mesma linha de base, mas o processo de classificação ocorre em cascata: o primeiro classificador recebe o conjunto de dados de entrada e gera uma saída, que será a entrada do segundo classificador e, assim sucessivamente até ao último classificador cuja saída gera o resultado do modelo (Figura 5.8b) [144]. Teoricamente, o *Boosting* pode ser constituído por algoritmos fracos. Isto porque, o método é baseado na análise de erros cometidos pelo classificador anterior, visando melhorar o desempenho a cada novo processo de classificação [145]. O grande benefício inerente é que a ponderação de cada instância muda ao longo do tempo, permitindo que o sistema otimize a sua decisão considerando os resultados a cada iteração. Assim, os dados mal agrupados são mais propensos a serem treinados a cada iteração, prestando-se mais atenção às instâncias mais difíceis de classificar [147]. Em contrapartida, a acumulação dos erros confere uma grande desvantagem a este método [144].

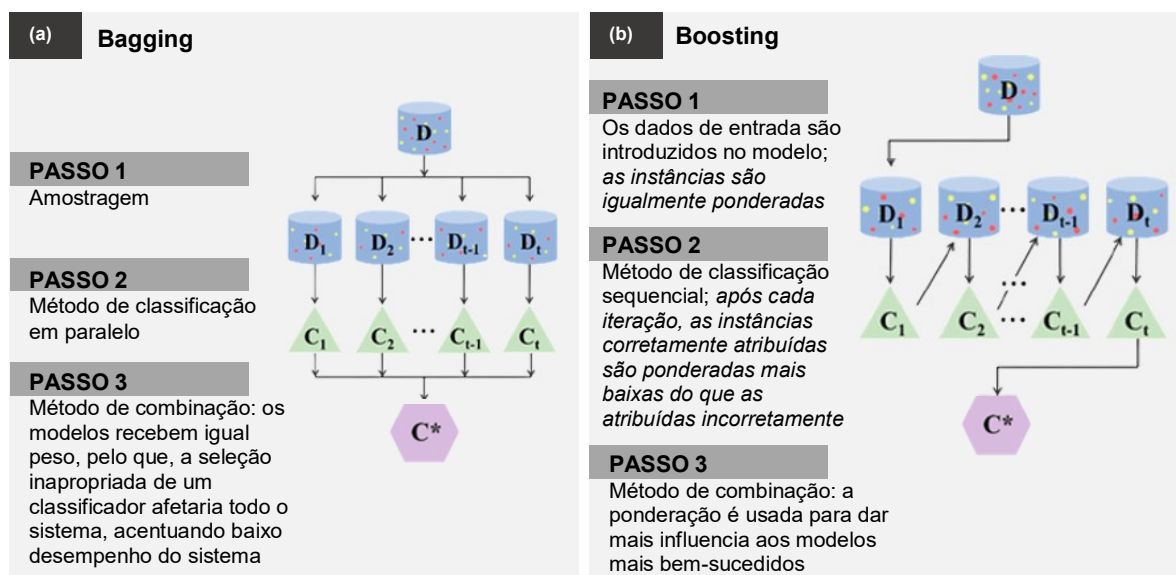


Figura 5.8 Métodos de Bagging e Boosting [Adaptado de [148]].

O método de subespaço é também uma abordagem muito comum em *Ensemble Learning*. Este método, também designado *features bagging*, utiliza amostragens dos dados de treino configuradas por um espaço aleatório de características. Conforme representado na Figura 5.9, das n características originais da base de dados são selecionadas aleatoriamente m características para construir os vários subespaços onde os classificadores vão atuar [149, 150]. Este modelo de classificação acaba por ser muito vantajoso sempre que a quantidade de dados de treino é relativamente pequena quando comparada com a dimensionalidade e, quando existem muitas características redundantes [151].

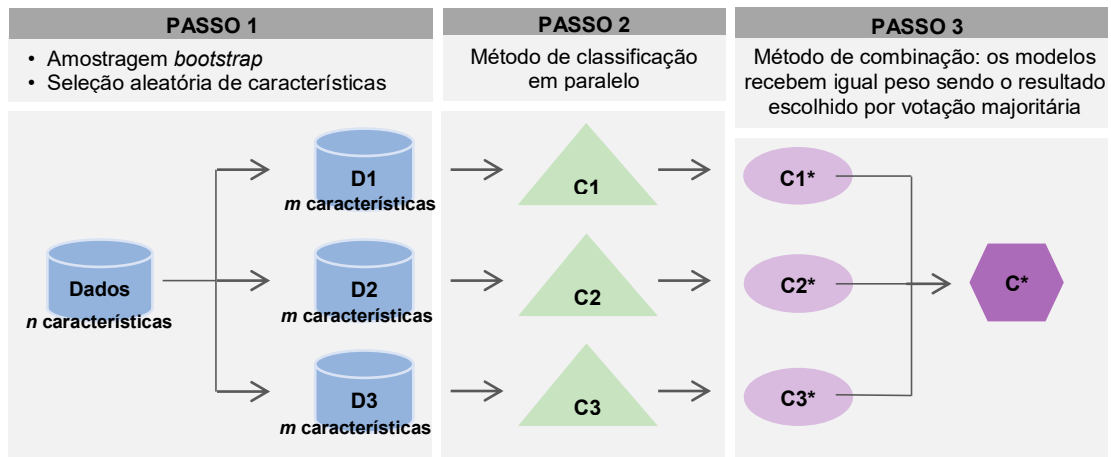


Figura 5.9 Método de subespaço aleatório [Adaptado de [150]].

Existem vários algoritmos que se enquadram nos modelos de *Ensemble Learning* citados. A Tabela 5.3 reúne os exemplos mais notáveis com uma breve explicação do mecanismo de atuação.

Tabela 5.3 Classificadores *Ensemble Learning* [77].

Classificador	Tipo de classificador	Interpretabilidade
<i>AdaBoost</i>	Boosting. Consiste na implementação de árvores de decisão em série, na qual cada uma individualmente é treinada para suprir as necessidades da anterior, sendo a precisão da classificação aumentada sucessivamente [123, 152]. Este método é amplamente utilizado devido à alta velocidade de treino, baixa complexidade e boa compatibilidade [153], contudo o processo de classificação é mais lento e complexo do que o método <i>Random Forest</i> [123].	
<i>Random Forest</i>	Bagging. É composto por várias árvores de decisão independentes, onde para classificar uma nova instância, cada árvore de decisão fornece uma classificação para os dados de entrada, sendo eleita a previsão mais votada como resultado [154, 155].	
<i>RUSBoost</i>	Boosting. Este algoritmo combina <i>AdaBoost</i> com RUS, do inglês <i>random under-sampling</i> . RUS é uma técnica de amostragem de dados que tenta aliviar o desequilíbrio da distribuição de instâncias na classe. Para tal, este algoritmo remove dados da classe majoritária (<i>undersampling</i>) ou adiciona dados à classe minoritária (<i>oversampling</i>). Ao contrário de outras técnicas que fazem este processo de remoção ou adição de forma “inteligente”, o RUS simplesmente o faz aleatoriamente até que a distribuição de classe desejada seja alcançada [156].	Difícil
<i>Subspace Discriminant</i>	Método de subespaço com classificadores de análise discriminante.	
<i>Subspace KNN</i>	Método de subespaço com classificadores de KNN.	

5.10 Avaliação do desempenho dos classificadores

5.10.1 Validação Cruzada

A Validação Cruzada (do inglês, “*Cross-Validation*”) é um método estatístico de avaliação do desempenho de algoritmos de *Machine Learning*. A técnica mais comum desta metodologia designa-se *k-fold* e consiste na divisão de um conjunto de dados em k subconjuntos de igual tamanho (ou muito semelhante). Subsequentemente, k iterações de treino e validação são executadas, de tal forma que, em cada uma, um dos subconjuntos é utilizado para validar o modelo e os restantes $k-1$ são utilizados para treinar o classificador. Como em cada iteração os conjuntos são cruzados sucessivamente, cada conjunto de dados acaba por ser validado. A Figura 5.10 ilustra o funcionamento deste método [157].

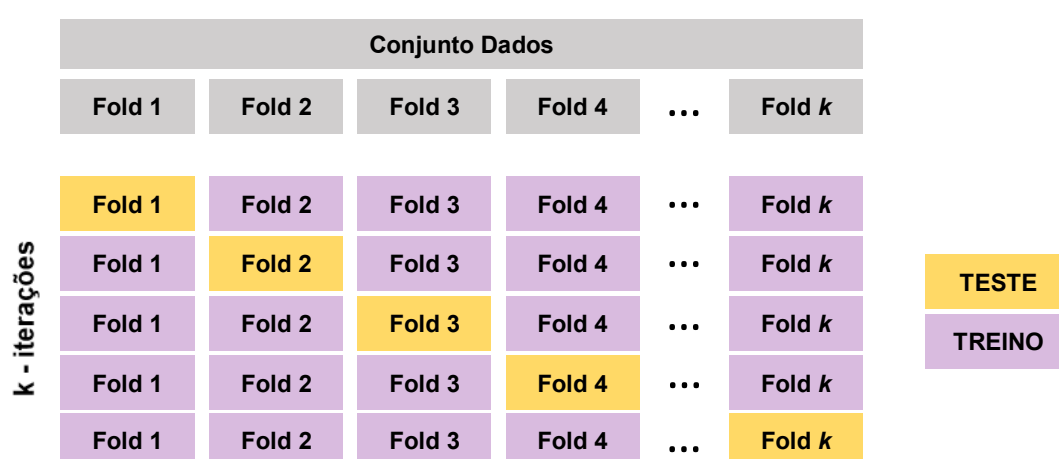


Figura 5.10 *Cross-Validation* com *k-folds* [Adaptado de [157]].

Quanto maior for o número de instâncias possíveis para treinar o classificador, maior será a probabilidade de o classificador se tornar mais preciso. Contudo, é importante ressaltar que o valor de k deve ser cuidadosamente escolhido, de forma a que cada subconjunto seja grande o suficiente para representar estatisticamente o conjunto de dados original. Ademais, embora o método seja bastante eficiente, existe um esforço computacional associado para repetir o procedimento k -vezes, sendo por isso recomendado para um pequeno conjunto de dados [158].

5.10.2 Medidas de apoio à decisão e Seleção de parâmetros

As medidas padrão utilizadas para a comparação do desempenho de modelos de classificação podem ser obtidas através da matriz de confusão (ou tabela de contingência). Representada na Tabela 5.4, a matriz de confusão reúne as possibilidades de resultados em problemas de classificação: considera-se que o sistema acerta quando se considera valores positivos os que o sistema julgou positivos (verdadeiros positivos) e valores negativos aqueles que o sistema julgou serem negativos (verdadeiros negativos); e considera-se que o sistema erra quando se considera valores positivos

aqueles que o sistema julgou como negativos (falso negativo) e valores negativos aqueles que o sistema julgou serem positivos (falso positivo) [158, 159].

Tabela 5.4 Matriz de confusão (ou tabela de contingência)

		Valor Verdadeiro	
		Positivo	Negativo
Valor Predito	Positivo	Verdadeiro Positivo (VP)	Falso Positivo (FP)
	Negativo	Falso Negativo (FN)	Verdadeiro Negativo (VN)

Geralmente, para decidir sobre a qualidade do modelo de classificação, a informação fornecida pela matriz de confusão é resumida por uma única métrica de valor real. A medida utilizada comumente designa-se por precisão - a porção de observações classificadas corretamente, onde quanto maior o valor de precisão melhor é o poder discriminativo do classificador – e, matematicamente traduz-se pela expressão [159]:

$$Precisão = \frac{VP + VN}{VP + FP + VN + FN} \quad 5.4$$

Metodologia

Este capítulo explana a metodologia adotada para a concretização do objetivo desta dissertação, totalmente desenvolvida em ambiente de programação com recurso ao *software* MATLAB® R2019a.

6.1 Base de Dados

Os dados de ECG analisados foram recolhidos por investigadores do *Human Neurobehavioral Laboratory* da Universidade Católica Portuguesa, no Porto, com a aprovação do Comitê Interno de Ética em Pesquisa e de acordo com a declaração de Helsinque. Os participantes foram recrutados a partir da mediatização do estudo nas redes sociais e através de *newsletters* de investigação. Foi utilizada uma amostra aleatória estratificada com 13 indivíduos, com faixa etária de 18 a 46 anos, na qual, todos os participantes voluntários cumprem os critérios de inclusão - maiores de 18 anos e consumidores diários de café ou produtos cafeinados - e são saudáveis, sem histórico de doenças cardiovasculares, distúrbios de abuso de substâncias, consumo de medicamentos que afetassem a atividade cardíaca ou função endócrina, condição física ou mental que pudesse comprometer as medidas fisiológicas, mulheres grávidas ou que estivessem a amamentar, e fumantes. A média de idade da amostra é 24,15 anos com desvio padrão de 7,71 anos, sendo 61,5% do sexo feminino e 38,5% do sexo masculino. As Tabelas 6.1 e 6.2 reúnem as características sociodemográficas e o perfil do consumo de cafeína dos participantes, respetivamente. Estes dados de autorrelato foram obtidos através do preenchimento de um questionário.

Tabela 6.1 Caracterização da amostra a nível sociodemográfico [57].

Medida Categórica	%
Gênero	
Feminino	61,5
Masculino	38,5
Estado Civil	
Solteiro	92,3
Casado/ num relacionamento	0
Divorciado/ separado	7,7
Víuvo	0
Nível de escolaridade	
Escola Primária	7,7
Secundário	61,5
Ensino Superior (licenciatura)	23,1
Ensino Superior (mestrado, doutoramento e pós-graduação)	7,7
Profissão	
Aluno	84,6
Outra	15,4

Tabela 6.2 Caracterização da amostra quanto ao padrão do perfil do consumo de cafeína [57].

Medida Categórica	%
Desfruta o café	
Sim	84,6
Não	15,4
Frequência de ingestão de café por dia	
Até uma vez por dia	38,5
2 vezes ao dia	7,7
2 a 3 vezes ao dia	23,1
Mais de 3 vezes ao dia	7,7
Raramente	15,4
Algumas vezes por semana	7,6
Razões para beber café	
Despertar	15,4
Social	7,7
Saúde	7,7
Vários (não específico)	69,2

O procedimento experimental seguiu o modelo de comparação intra-sujeitos e consistiu em quatro fases: (1) acolhimento, consentimento informado, instruções, aplicação do questionário e configuração do equipamento; (2) tarefa de linha de base; (3) consumo da modalidade em estudo; e (4) fase de monitorização. Desta forma, após passarem por uma triagem de elegibilidade, os participantes foram encaminhados para quatro sessões laboratoriais em dias consecutivos, no mesmo período da manhã, a fim de evitar a variabilidade diurna nos parâmetros do sinal. Garantiu-se que o estudo se realizou num ambiente laboratorial controlado e que os participantes mantiveram nos dias prévios o mesmo

padrão de ingestão de cafeína, evitando psicoestimulantes como chocolate, cola ou mesmo café duas horas antes da sessão. Em cada visita laboratorial, foi atribuída aleatoriamente a cada participante uma das quatro condições em análise: café, descafeinado, OF com cafeína, OF sem cafeína (os OF foram produzidos no Centro de Biotecnologia e Química Fina na Universidade Católica Portuguesa por uma equipa de investigação experiente na área [160, 161]). A cada visita realizada, os participantes tinham menos uma condição em falta para sortear. Consequentemente, o processo de randomização foi totalmente cego para os participantes e para os investigadores assistentes responsáveis pela recolha dos dados [57].

Após 5 min de repouso na posição sentada, enquanto os participantes preenchem um questionário e se familiarizam com o ambiente de laboratório, elétrodos foram colocados nos participantes em posições adequadas para a recolha do sinal. Posteriormente, e antes do consumo de qualquer modalidade, foi realizada a tarefa de linha de base. Para esta etapa, os participantes foram solicitados a examinar e avaliar se pares de imagens eram iguais ou diferentes. Foi também realizada uma tarefa comportamental para avaliar o nível de desempenho cognitivo antes da ingestão de cafeína. Em seguida, após o consumo da modalidade atribuída aleatoriamente, foi monitorizada a atividade cardíaca dos participantes. Durante esta fase de monitorização, os participantes foram predispostos a um conjunto de tarefas específicas: avaliação do estado de alerta segundo uma escala variável entre “alerta/ capaz de se concentrar”, “ansioso”, “energético”, “confiante”, “irritado”, “nervoso”, “sonolento” e “comunicativo”; realização do Teste de Rede de Atenção (ANT, do inglês “*Attentional Network Test*”), um teste computadorizado utilizado para medir o desempenho do participante através da avaliação de 3 componentes separadas: alerta, orientação e controlo executivo; e realização do Teste de Variáveis de Atenção (T.O.V.A, do inglês “*Test of variables of attention*”), um teste de desempenho contínuo para a avaliação da atenção e impulsividade [57].

Todos os sinais eletrocardiográficos foram adquiridos a uma taxa de amostragem de 100Hz usando o sistema de aquisição de dados Biopac MP-160, com o amplificador ECG100C e o software de aquisição BIOPAC Acqknowledge (Biopac System Inc., Santa Barbara, CA, EUA) conectado a um computador. O ECG foi monitorizado com uma configuração padrão de elétrodos descartáveis de Ag-AgCl, colocados na clavícula direita e no sítio precordial V6, após limpeza da pele com álcool para minimizar a impedância e promover um bom contato entre o elétrodo e a pele [57, 162].

6.2 Estrutura da Investigação

A estratégia de análise dos dados subdivide-se em três etapas: (1) Importação e pré-processamento dos sinais, (2) Processamento dos sinais: processamento efetivo, análise não linear e extração de métricas e (3) Classificação dos sinais: aplicação de técnicas de Inteligência Artificial. A Figura 6.1 explana a infraestrutura do algoritmo desenvolvido com base na metodologia adotada e, para melhor compreensão, deve fazer-se acompanhar pelo conteúdo textual deste capítulo.

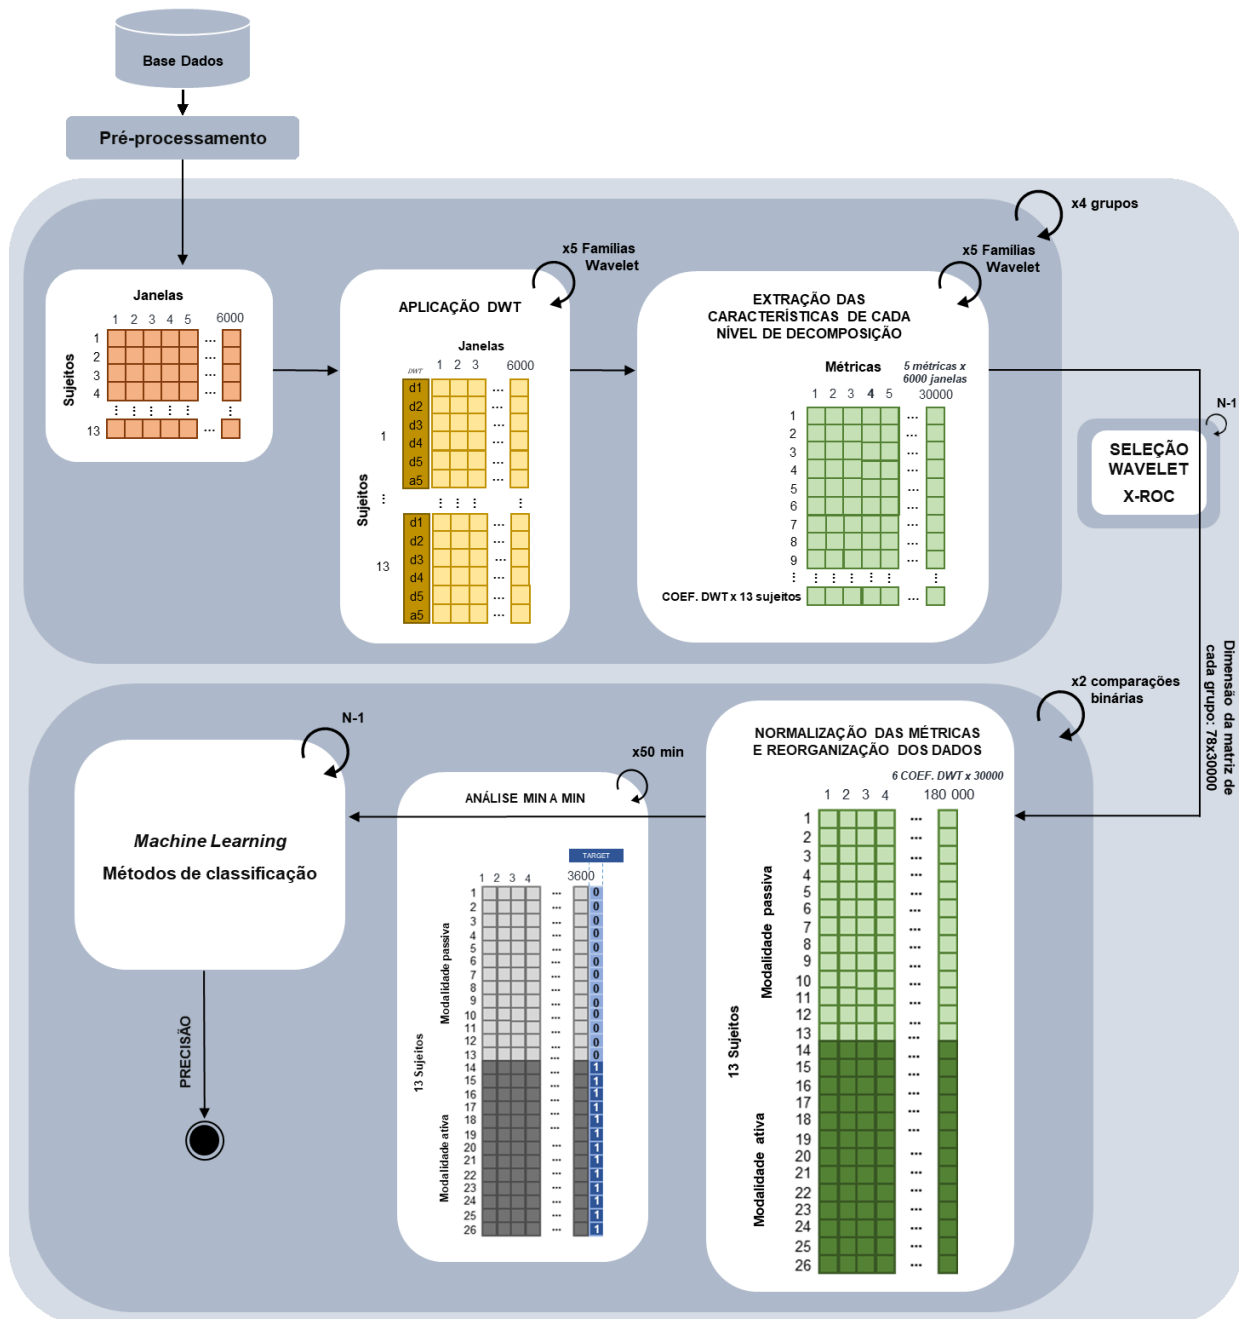


Figura 6.1 Estrutura do algoritmo desenvolvido com base na metodologia adotada.

O pré-processamento de sinal é uma das etapas mais importantes quando se estruturam modelos que pretendem dar uma resposta, nomeadamente na área da saúde em que a tomada de decisão, diagnóstico e/ou tratamentos médicos são decisivos. Os dados brutos contêm contaminações que são geralmente grandes o suficiente para camuflar as características de pequena amplitude do sinal que são de interesse fisiológico ou clínico [163]. Os ruídos possíveis são derivados (i) dos instrumentos utilizados e (ii) do ambiente de experimentação [164]:

- i) Devida à baixa amplitude dos sinais biomédicos são necessários fatores de ampliação elevados, o que leva conseqüentemente à amplificação do ruído. Naturalmente, estas interferências podem ser significativamente reduzidas com a escolha cuidadosa de

dispositivos de alta qualidade, nomeadamente na utilização de amplificadores com elevada impedância de entrada e alta taxa de rejeição em modo comum [164].

- ii) Estas perturbações podem ter origem em (1) desvios da linha de base – é um artefacto de variação lenta que se deve à variação da impedância pele-eléctrodo, podendo ocorrer em consequência de movimentos respiratórios suaves do paciente. Este ruído manifesta-se na forma de componente de baixa frequência adicionada ao sinal.; (2) interferência na linha de energia – ruído de natureza estacionária, gerado pelo campo eletromagnético da linha de energia e apresenta o seu pico em 50-60 Hz; (3) artefactos de movimento – gerados pelo afastamento do eléctrodo em relação à zona de contacto na pele; e (4) ruído muscular – esta contaminação é bastante frequente visto que o sinal oriundo das contrações do músculo esquelético se sobrepõe ao ECG [164].

A fim de remover discrepâncias e dimensionar os recursos para um intervalo equivalente, um conjunto de técnicas de pré-processamento foram aplicadas aos 52 sinais (13 sujeitos x 4 modalidades). Primeiramente, estudou-se a projeção de filtros digitais passa-banda. Foram analisados os filtros *Butterworth*, *Elliptic* e *Chebyshev Type II*, sendo que os melhores resultados foram obtidos com a topologia *Butterworth* com uma frequência de corte 2-49Hz. Em seguida, a amplitude de cada sinal foi normalizada de acordo com a expressão matemática:

$$x(n) = \frac{x(n)}{\sum_{n=0}^{N-1} x^2(n)} \quad 6.1$$

onde, N representa o tamanho do sinal. Ao sinal normalizado $x(n)$ foi removido o valor médio. Os sinais encontram-se aptos para a segunda etapa da metodologia, a qual inicia com o janelamento do sinal. Este processo consiste numa janela deslizante que percorre o sinal segmentando-o em porções de 0,5 segundos (50 amostras), resultando 6000 segmentos para cada um dos 52 sinais. Em seguida, e entrando no processamento efetivo, procedeu-se a uma análise multibanda de cada segmento através da DWT. De forma a selecionar a Wavelet que melhor se ajusta à dinâmica do sinal ECG nesta abordagem, foram testadas as famílias Db, Sym, Coif, Bior e rBio para diferentes níveis de decomposição através do classificador X-ROC. Este processo consistiu na avaliação do poder discriminativo de um conjunto de métricas extraídas individualmente de cada nível, tendo a Sym5 apresentado os melhores resultados. Para todos os níveis de decomposição, foram extraídas as métricas energia, entropia, expoente de Lyapunov, expoente de Hurst e dimensão fractal de Higuchi por cada segmento, organizando-se os resultados em quatro matrizes individuais para cada modalidade, cada uma com dimensão 78x30000, onde as linhas representam os coeficientes de aproximação e detalhe resultantes da aplicação DWT associados ao sinal de cada indivíduo (6x13, respetivamente) e as colunas as métricas extraídas de cada segmento de sinal (5x6000, respetivamente). Estes dados foram normalizados e reorganizados para o processo de classificação de forma a distinguir as duas comparações binárias. Então, 2 matrizes de métricas foram criadas: descafeinado/café e OF_placebo /OF_cafeína, cada uma com dimensão de 26x180000 apresentando para cada um dos 13 sujeitos, submetidos à substância ativa e ao placebo (13+13), todas as métricas extraídas para todos os níveis de composição em cada segmento (6x30000, respetivamente). A partir

destas matrizes, para cada uma das comparações, foram geradas 50 matrizes com dimensão 26x3600 permitindo assim a aplicação dos métodos classificativos de 1 em 1 min. Assim, as colunas de cada matriz reúnem a informação referente às 5 métricas extraídas de cada nível de decomposição durante 1 min (120 células = 60/0,5 s).

Finalmente, o primeiro passo para a terceira etapa é identificar as diferentes modalidades em estudo de uma forma que o computador compreenda. Por outras palavras, um conjunto de valores binário é concatenado a cada matriz – vetor coluna target, no qual, por definição, à substância ativa é atribuído o valor 1 e ao placebo o valor 0. Estando agora bem definidos ambos os grupos em cada classificação binária, os dados estão prontos para serem submetidos ao processo de classificação.

Assim, as 100 matrizes alimentaram individualmente a APP *Classification Learner* do MATLAB®, no qual foram testados 23 modelos de classificação (Tabela 6.3) treinados por validação cruzada *leave-one-out*.

Tabela 6.3 Os vinte e três modelos de classificação e os seus classificadores correspondentes [77, 165].

Métodos de Classificação	Classificador	Parâmetros por default
Árvore de Decisão	<i>Fine Tree</i>	Número máximo de divisões = 4
	<i>Medium Tree</i>	Número máximo de divisões = 20
	<i>Coarse Tree</i>	Número máximo de divisões = 100
Análise Discriminante	<i>Linear Discriminant</i>	Estrutura de covariância: completa
Regressão Logística		Estrutura de covariância: completa
<i>Naïve Bayes</i>	<i>Gaussian Naïve Bayes</i>	-
SVM	<i>Linear SVM</i>	Nível de restrição da região = 3
	<i>Quadratic SVM</i>	Nível de restrição da região = 3
	<i>Cubic SVM</i>	Nível de restrição da região = 4
	<i>Fine Gaussian</i>	Nível de restrição da região = 3
	<i>Medium Gaussian</i>	Nível de restrição da região = 3
	<i>Coarse Gaussian</i>	Nível de restrição da região = 1
KNN	<i>Fine KNN</i>	Número de vizinhos = 1
	<i>Medium KNN</i>	Número de vizinhos = 10
	<i>Coarse KNN</i>	Número de vizinhos = 100
	<i>Cosine KNN</i>	Número de vizinhos = 10
	<i>Cubic KNN</i>	Número de vizinhos = 10
	<i>Weighted KNN</i>	Número de vizinhos = 10
	Ensembles	<i>Boosted Trees</i>
<i>Bagged Trees</i>		Número máximo de divisões = n-1 (n = número de observações na amostra de treino)
<i>Subspace Discriminant</i>		Estrutura de covariância: completa
<i>Subspace KNN</i>		Número de vizinhos = 3
<i>RUSBoosted Trees</i>		Número máximo de divisões = 150

Uma das dificuldades inerentes ao processo de classificação e à estatística multivariada é a visualização de dados que possuem muitas variáveis. Em face deste problema, o *Classification Learner* oferece um recurso que visa diminuir a dimensionalidade removendo informações redundantes e

evitando o *overfitting*: a Análise de Componentes Principais (PCA, do inglês "*Principal Component Analysis*"). Para alcançar esta simplificação, este método quantitativamente rigoroso, gera um novo conjunto de variáveis designadas de componentes principais onde cada uma é uma combinação das variáveis originais. O PCA está padronizado para manter os componentes que explicam 95% da variância. Entretanto, o sistema também foi treinado para valores de PCA de 100%, 80%, 70%, 50%, 20%, 10%, 5% e 1%. Na discussão dos resultados é importante considerar que valores mais altos de PCA são mais propensos ao risco de *overfitting*, enquanto que, valores mais baixos correm o risco de remover dimensões úteis.

Os valores de precisão de cada classificador, resultantes dos métodos de treino aplicados a cada minuto, foram exportados e armazenados em ficheiros Excel e analisados estatisticamente através do cálculo médio destes 50 minutos. Assim, para facilitar a interpretação dos resultados, foram criados 9 ficheiros individuais para cada valor de PCA treinado, onde cada um possui 3 folhas: (1) a *performance* dos classificadores nas classificações binárias descafeinado/café e (2) OF_placebo/OFCafeína e (3) as curvas de precisão para cada um dos 23 classificadores nas respetivas condições de treino, obtidas pelas sucessivas análises independentes em função do tempo.

6.3 Apresentação e Discussão dos Resultados

Os resultados da metodologia aplicada encontram-se no Apêndice de A a I, respetivamente para cada PCA treinado. Inicialmente, e para facilitar a análise deste grande volume de resultados, o foco da discussão centrou-se nos valores médios de precisão, onde se verifica que os melhores valores foram obtidos para diferentes classificadores em cada PCA treinado.

Quando o sistema foi treinado com PCA=100%, para ambas as classificações binárias, como se pode ver no Apêndice A, os classificadores de árvore de decisão foram aqueles que revelaram melhor poder discriminativo, com valor médio de precisão de 50,2% para descafeinado/café e 65,5% para OF_placebo/OFCafeína. Esta família de classificadores também revelou a melhor *performance* de treino com PCA 95%, 80%, 70% e 50% (Apêndices B a E, respetivamente), para a comparação descafeinado/café, com valores de precisão médios compreendidos entre 44,9% a 46,8%. Entretanto, para estes mesmos valores de PCA treinados, para a comparação OF_placebo/OFCafeína, o classificador *Fine Gaussian* revelou a melhor precisão de classificação com valores médios entre 67,3% a 72%. Relativamente ao treino do sistema com PCA 20%, 10% e 5% (Apêndices F a H, respetivamente), para a classificação binária OF_placebo/OFCafeína, os classificadores *Quadratic SVM*, *Medium KNN*, *Cubic KNN* revelaram a melhor *performance* de classificação com valores médios de precisão compreendidos entre 68,2% a 69,7%. E, para a comparação descafeinado/café, com PCA 20% os classificadores *Bagged Trees* e *Fine KNN* apresentam os melhores resultados com uma *performance* média de 47,9% e 47,5%, respetivamente. Nesta mesma classificação, para o treino com PCA 10% e 5%, a melhor precisão média manifestou-se nos classificadores *Subspace KNN* e *Fine KNN* com valores compreendidos entre 47,2% e 47,6%. Finalmente, quando o sistema foi treinado com PCA 1%, para a comparação binária descafeinado/café, os classificadores *Bagged Trees*, *Fine KNN* e *Subspace KNN* revelaram o melhor poder discriminativo com uma *performance* de 47,2%. E, para a

comparação OF_placebo/OFF_cafeína, o classificador *Quadratic SVM* apresentou a melhor *performance* com 68,6%.

Os restantes resultados obtidos não mencionados clarificam que esses classificadores não se revelaram tão eficientes no respetivo processo de classificação. Assim, é de especial interesse compreender as curvas de precisão dos classificadores ao longo do tempo que revelaram melhor *performance*. As Figuras 6.2 a 6.10 reúnem estes resultados.

Primeiramente, analisando superficialmente as curvas de precisão, verifica-se que a amplitude da *performance* dos classificadores encontra-se dentro do esperado. Neste ponto, é importante reforçar a ideia de que o objetivo não é avaliar os classificadores (necessidade de elevadas precisões), mas sim verificar o efeito da cafeína ao longo do tempo através da sua capacidade discriminativa. Neste caso, quanto maior for a precisão do classificador, maiores são as diferenças entre grupos e, conseqüentemente, maior é o poder discriminativo do classificador na respetiva comparação binária. Além disso, as características fisiológicas intrínsecas a cada indivíduo, impedem e condicionam à partida a possibilidade de encontrar taxas elevadas de precisão (próximas de 100%) e também é de esperar que, a precisão ao longo do tempo decaia à medida que a cafeína é metabolizada no organismo, limitando os classificadores.

Examinando individualmente as curvas de precisão, constata-se que os valores de precisão obtidos na classificação descafeinado/café foram muito menores do que aqueles obtidos na classificação OF_placebo/OFF_cafeína. Estes valores de precisão indicam que as diferenças entre as modalidades café e, o seu placebo, descafeinado, consumidos através do mesmo veículo, não são tão significativas como na outra comparação binária em estudo. Contudo, com base na literatura estudada e apresentada no Capítulo 2, a cafeína revela efeitos fisiológicos no organismo humano. Ainda assim, sabe-se que esse impacto fisiológico é individualmente variável e dependente de vários fatores. Desta forma, pode-se inferir que estes valores de baixa amplitude podem ter origem (1) na baixa sensibilidade às doses de cafeína administradas através do café, (2) no efeito psicológico (ou condicionado a partir do consumo prévio), uma vez que, o aroma, o cheiro e o ato de beber podem despertar comportamentos associados à real ingestão da substância pela ativação do sistema nervoso, ou (3) no facto de que ambas as modalidades foram servidas da mesma máquina e resíduos de cafeína podem ter passado para a bebida descafeinada. Porém, nos primeiros minutos de análise seria de esperar que, nos indivíduos mais sensíveis, os valores de precisão fossem notavelmente mais baixos do que no restante período de recolha de sinal. Tal situação verificou-se muito subtilmente em algumas das curvas de precisão e tem origem nos efeitos psicológicos, visto que, de acordo com os estudos científicos, a presença de cafeína na mucosa oral pode induzir por si só respostas cerebrais, mesmo antes da absorção de qualquer quantidade de cafeína. Ademais, a elevada amplitude das curvas de precisão revela novamente um contrassenso com a literatura, uma vez que, esta oscilação representa instantes sucessivos de diferença e semelhança entre as duas modalidades. Sabe-se que isto não corresponde à realidade, visto a quantidade de cafeína administrada através do café estar totalmente disponível para absorção no mesmo instante.

Em contrapartida, pelas curvas de precisão OF_placebo/OFF_cafeína verificam-se diferenças entre as duas modalidades, as quais são manifestadas por alterações a nível cardíaco que não são passíveis

de identificar com os recursos usados. Isto é, os métodos de classificação apenas revelam que existem diferenças entre os sinais fisiológicos através da comparação entre as métricas dos grupos ativo e placebo. Por outras palavras, não se pode concluir sobre o real comportamento da cafeína a nível fisiológico, isto é, por exemplo, um aumento ou diminuição da frequência cardíaca ou a manifestação de eventos arrítmicos. Contudo, consegue-se avaliar a eficiência do OF. Relativamente ao poder de dissolução, o mesmo é visível nos primeiros minutos de análise pelos elevados valores de precisão. Entretanto, relativamente à forma antecipada da libertação da cafeína pelo OF, que também não se consegue avaliar diretamente no presente estudo, pode-se inferir que a quantidade de cafeína se manteve elevada ao longo do tempo. Isto porque, sendo o OF placebo desprovido de cafeína, a constante amplitude dos valores de precisão visível ao longo do tempo corrobora alterações no comportamento efetivo do individuo. De outro modo, a presença frequente de picos associados a oscilações positivas ou negativas seria um indicador da libertação de uma quantidade de cafeína nesses instantes de tempo, conferindo uma administração oral intervalada. As Figuras 6.7, 6.8 e 6.10 ilustram esta situação quando o sistema foi treinado com o classificador *Quadratic SVM*, contudo como foi um ato isolado será mais provável ser proveniente de ruído, erros associados ou mesmo do próprio conceito matemático do classificador, do que um exemplo de administração oral intervalada. Além disso, a análise destas curvas tem menos relevância, uma vez que, as mesmas servem-se de pouca informação para justificar a variância entre os sinais.

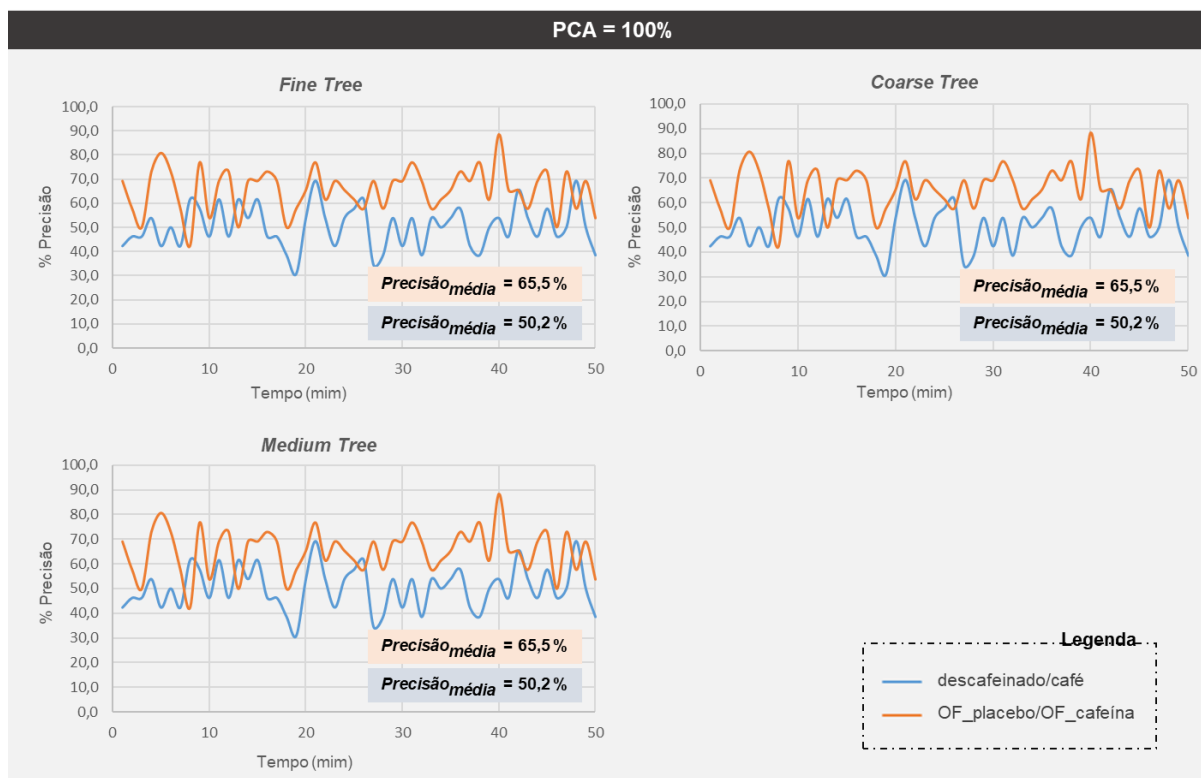


Figura 6.2 Curvas de precisão dos classificadores com os melhores resultados para ambas as classificações binárias, quando o sistema foi treinado com PCA=100%.

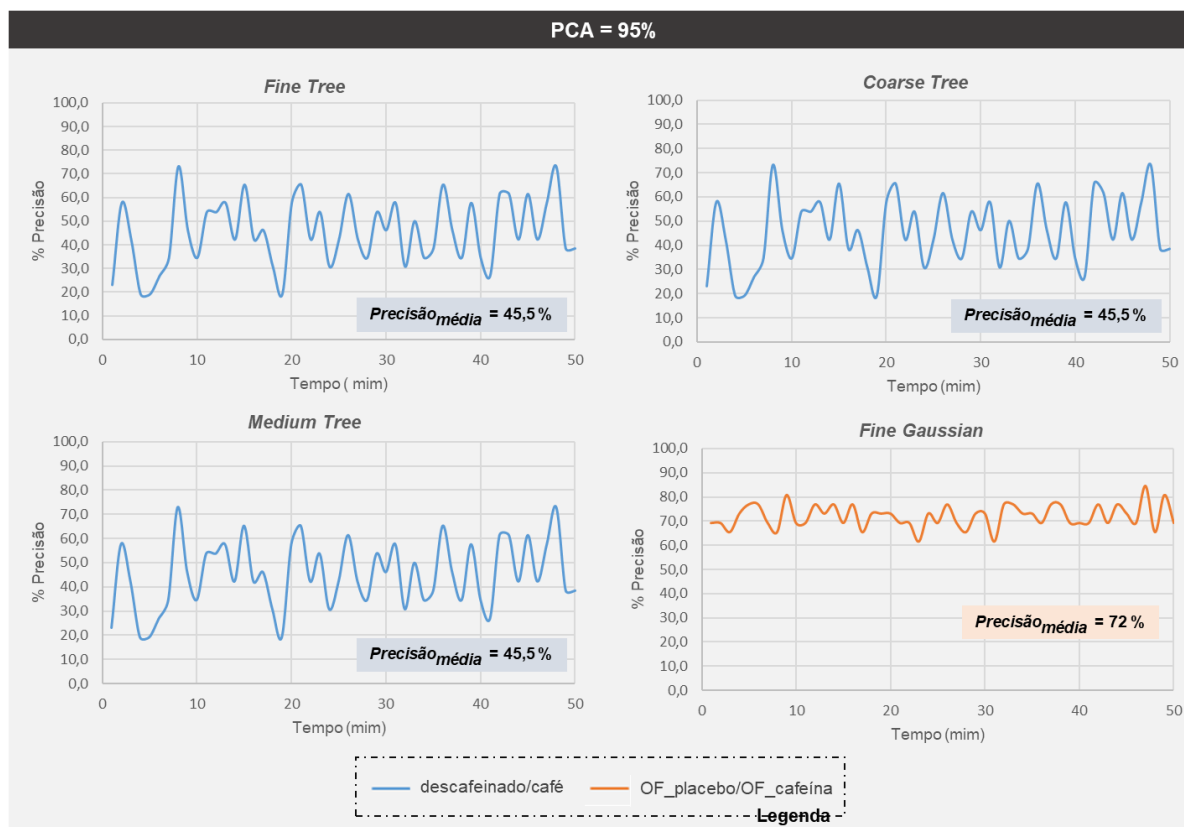


Figura 6.3 Curvas de precisão dos classificadores com os melhores resultados para ambas as classificações binárias, quando o sistema foi treinado com PCA=95%.

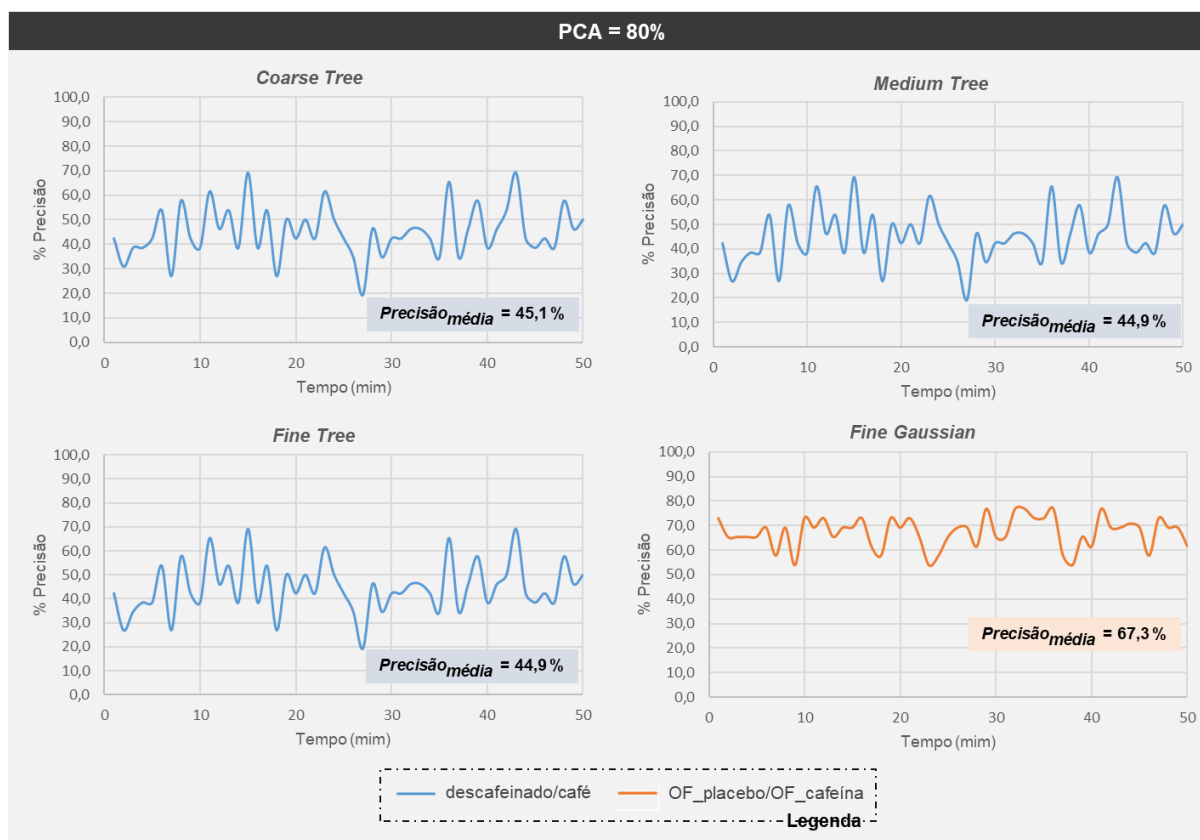


Figura 6.4 Curvas de precisão dos classificadores com os melhores resultados para ambas as classificações binárias, quando o sistema foi treinado com PCA=80%.

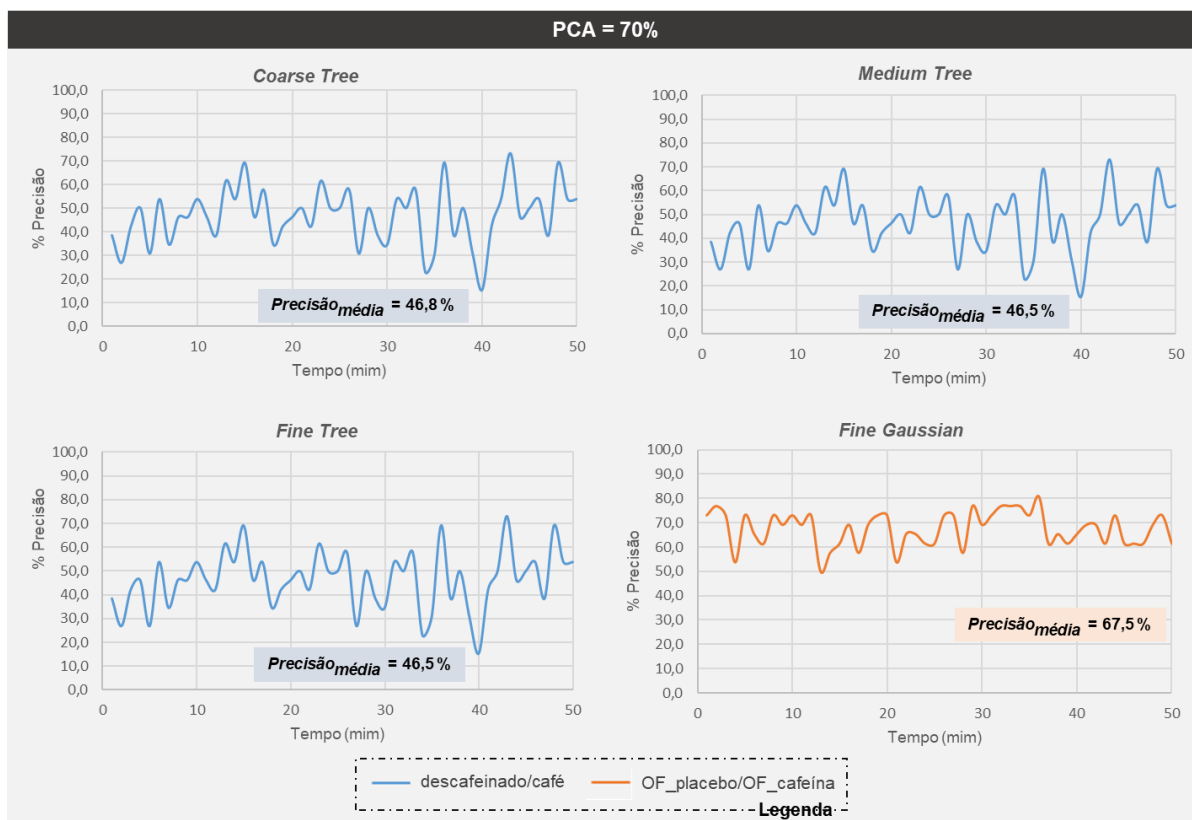


Figura 6.5 Curvas de precisão dos classificadores com os melhores resultados para ambas as classificações binárias, quando o sistema foi treinado com PCA=70%.

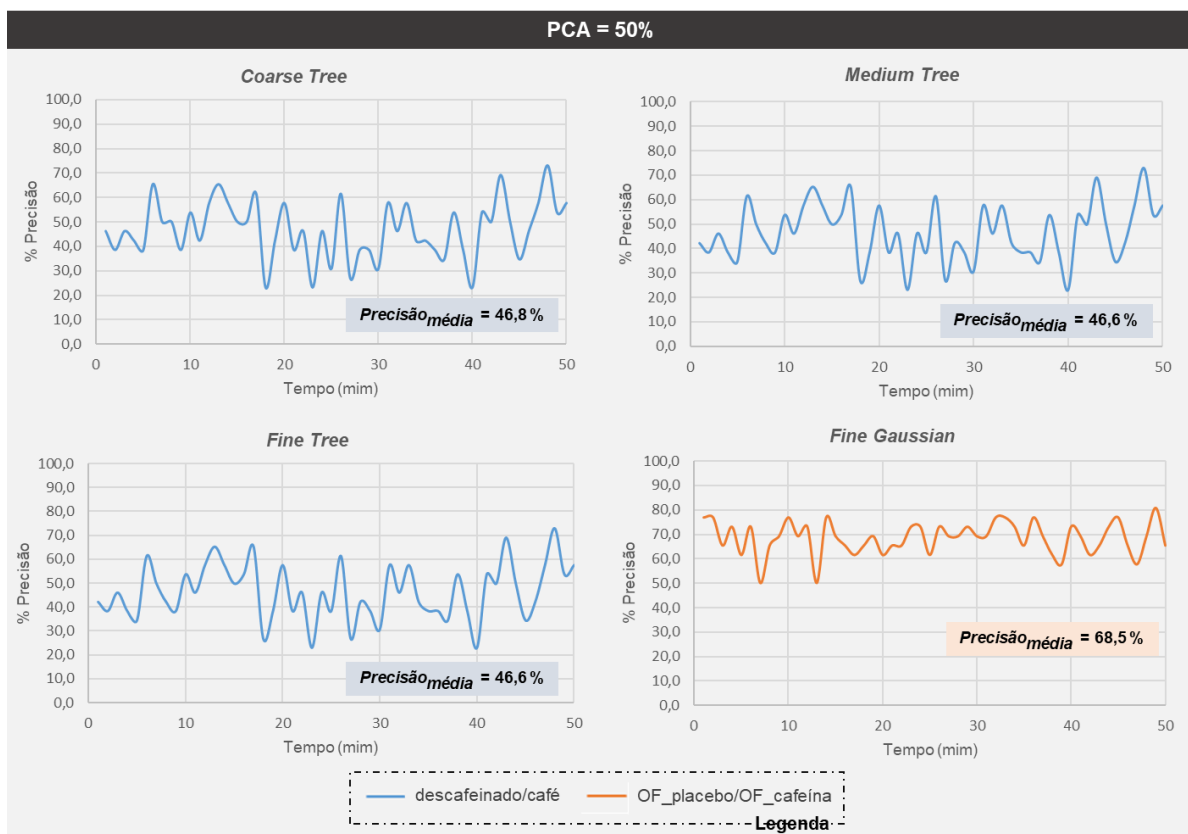


Figura 6.6 Curvas de precisão dos classificadores com os melhores resultados para ambas as classificações binárias, quando o sistema foi treinado com PCA=50%.

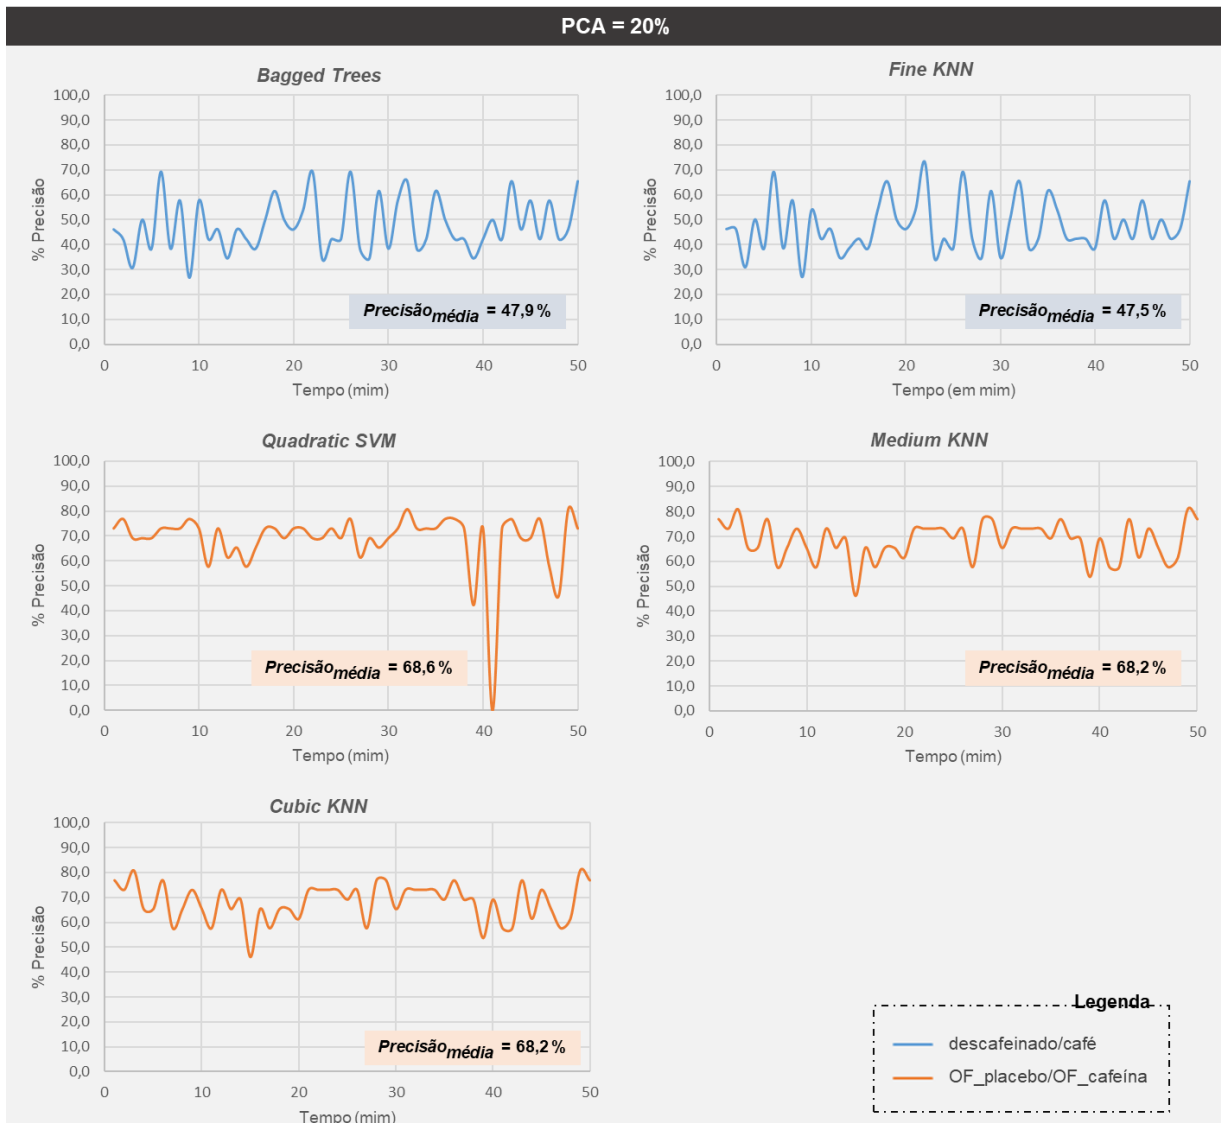


Figura 6.7 Curvas de precisão dos classificadores com os melhores resultados para ambas as classificações binárias, quando o sistema foi treinado com PCA=20%.




Figura 6.8 Curvas de precisão dos classificadores com os melhores resultados para a classificação binária descafeinado/café, quando o sistema foi treinado com PCA=20% - continua na próxima página

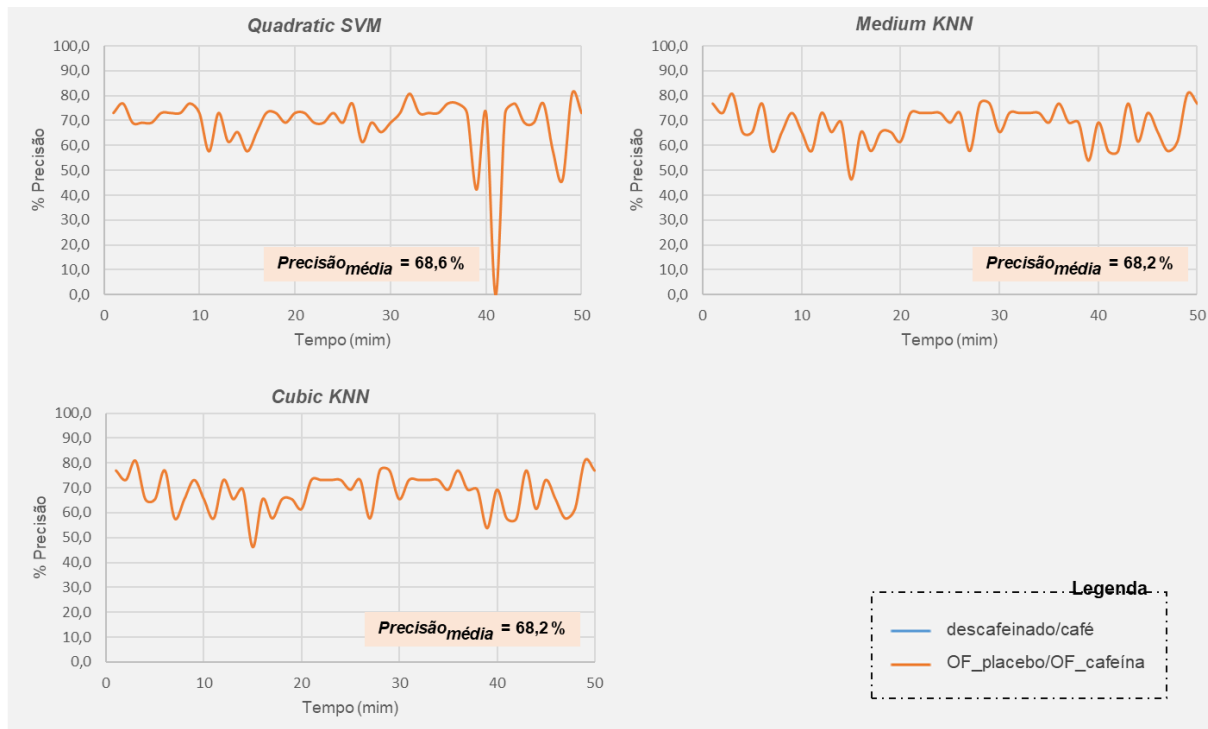


Figura 6.8 Curvas de precisão dos classificadores com os melhores resultados para a classificação binária OF_placebo/OF_cafeína, quando o sistema foi treinado com PCA=20% - *continuação*

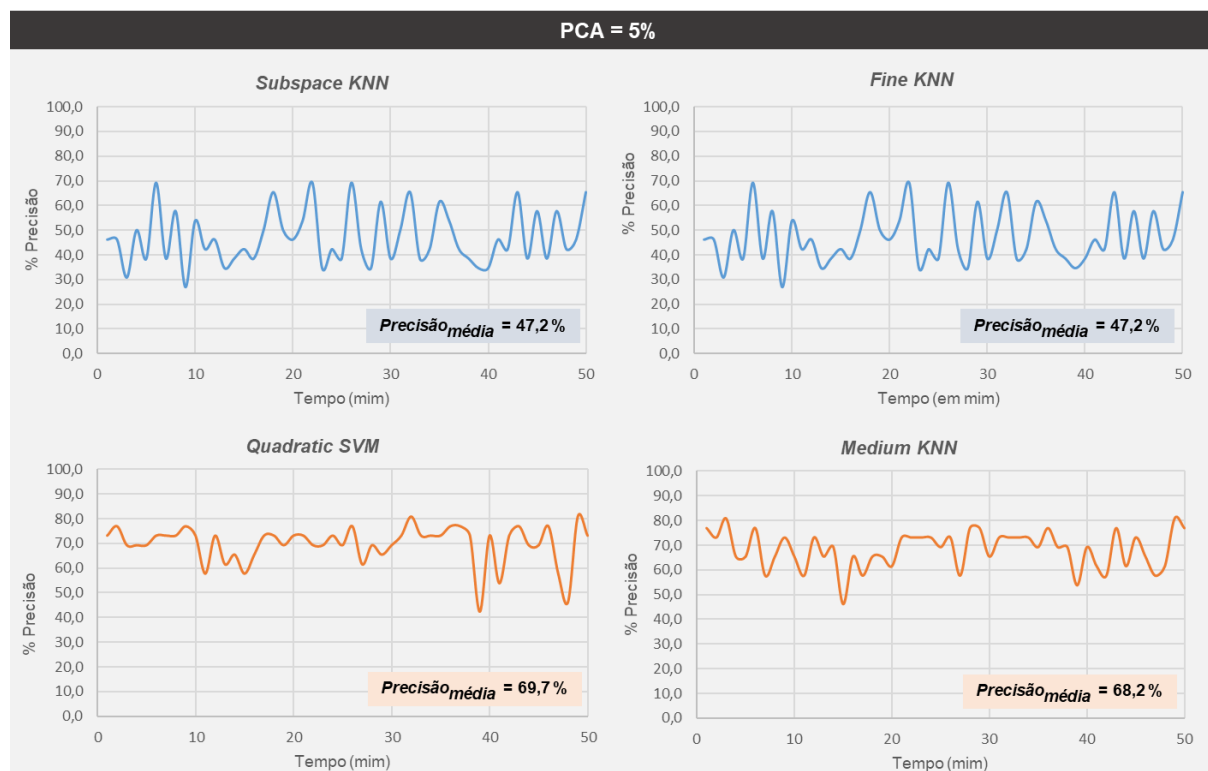


Figura 6.9 Curvas de precisão dos classificadores com os melhores resultados para ambas as classificações binárias, quando o sistema foi treinado com PCA=5% - *continua na próxima pagina*




Figura 6.9 Curvas de precisão dos classificadores com os melhores resultados para ambas as classificações binárias, quando o sistema foi treinado com PCA=5% - *continuação*

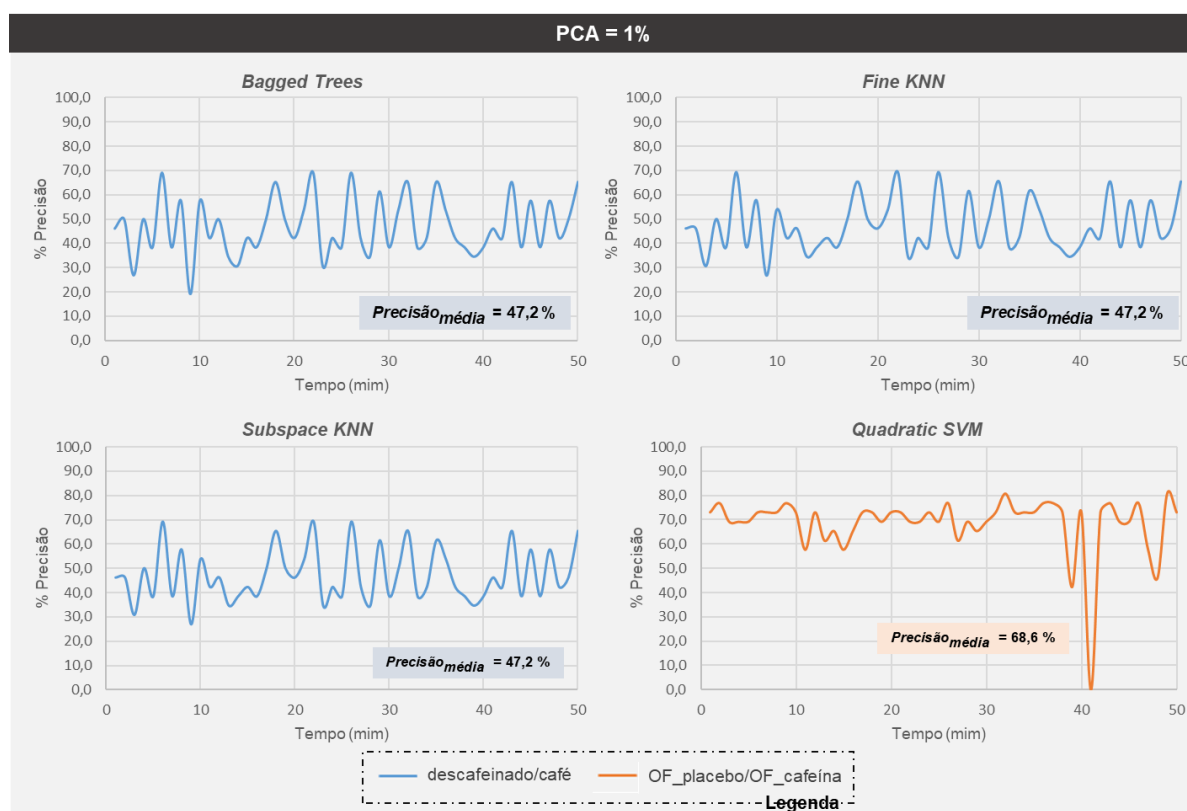


Figura 6.10 Curvas de precisão dos classificadores com os melhores resultados para ambas as classificações binárias, quando o sistema foi treinado com PCA=1%.

De uma forma geral, como ilustra o gráfico de barras apresentado na Figura 6.11, as percentagens de precisão de cada classificador foram semelhantes para os vários níveis de treino de PCA, podendo inferir-se que, das métricas selecionadas, existe informação redundante. Por outras palavras, para as mesmas conclusões do estudo, apenas algumas das métricas teriam sido suficientes. Ainda assim, de entre os resultados selecionados, salientam-se os classificadores de árvores de decisão no treino PCA 100% para a comparação descafeinado/café e *Fine Gaussian* no treino PCA 95% para a comparação OF_placebo/OF_cafeína, explanados na Figura 6.12. Ainda assim, é importante mencionar que existem picos discriminativos de maior amplitude que são camuflados pela análise da precisão média.



Figura 6.11 Comparação dos resultados selecionados para cada classificação binária.

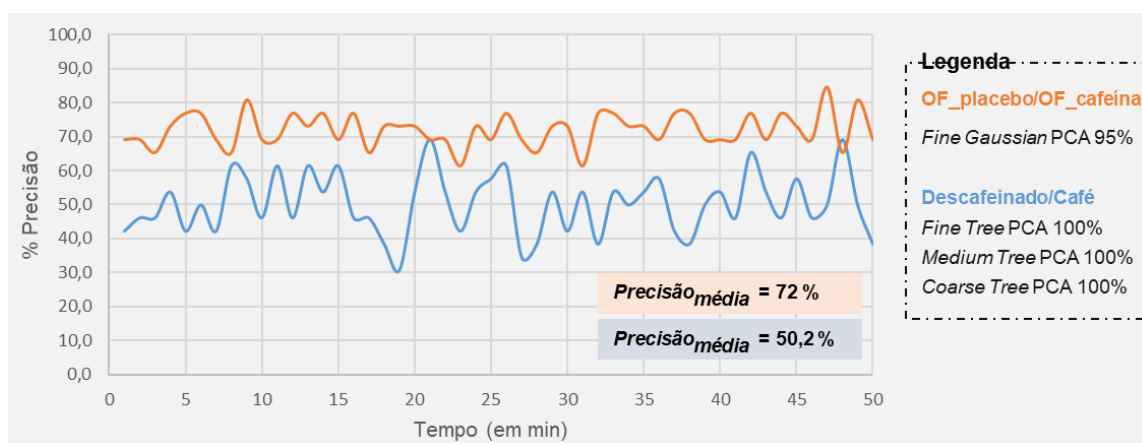


Figura 6.12 Curvas de precisão dos classificadores com os melhores resultados da investigação.

Após a análise e discussão das curvas de precisão de forma individual, torna-se conveniente compreender a interação entre as duas modalidades ativas. Através do gráfico presente na Figura 6.12, constata-se que o comportamento das trajetórias afetas à administração de cafeína por café e OF_cafeína são muito semelhantes. Contudo, como as curvas de precisão revelam significados diferentes não temos informação suficiente para inferir que não existem diferenças significativas entre essas modalidades, nomeadamente em termos comportamentais fisiológicos sob o indivíduo. Para esta análise, seria impreterível adicionar à metodologia, o estudo da comparação direta entre o OF_cafeína e o café.

Desta forma, embora os resultados não tenham sido tão satisfatórios na análise descafeinado/café, conseguiu-se comprovar que os benefícios enunciados no Capítulo 2 sobre os OF, especialmente no controlo da taxa de libertação da substância ativa, efetivamente funcionam com a cafeína. OF de cafeína tornam-se extremamente promissores e versáteis, sobretudo em casos de específicos, quando consumir cafeína através do café tradicional não promove o efeito esperado ou não é conveniente, e quando se deseja um rápido efeito de início. Fala-se numa solução para condições em que manter o organismo num pico de *performance* é crucial, como para profissionais de saúde principalmente em turnos noturnos; médicos cirurgiões em longas horas de cirurgia; profissionais de emergência médica; forças policiais, militares e bombeiros durante serviços de longas horas principalmente em situações de catástrofe; atletas de alta competição; e pilotos. Entretanto, pode mesmo ser interessante noutras situações, como estéticas, no caso em que, a pessoa prescinde das sensações que beber um café fornece em detrimento da coloração dos dentes; ou mesmo para quem não aprecia esta bebida, mas necessita dos seus efeitos psicofisiológicos.

Conclusão e Perspetivas Futuras

A cafeína é a substância psicoativa mais popular e procurada no mundo devido ao seu poderoso impacto no organismo humano, nomeadamente pelo custo-benefício e pelos efeitos fisiológicos que promove a nível cognitivo e desempenho físico. Atualmente, existe uma grande disponibilidade de produtos cafeinados no mercado, estimulando o interesse da comunidade científica sobre as formas de uso da cafeína. OF são uma forma farmacêutica, que funciona como um veículo de entrega onde podem ser incorporadas diversas substâncias, com fácil administração, rápida dissolução e absorção e elevada biodisponibilidade sendo, por isso, uma tecnologia bastante aliciante para a entrega da cafeína. A entrega de cafeína através destes sistemas de libertação controlada representa um grande desafio para os investigadores: quer pela legislação não ser clara quanto aos métodos de desenvolvimento e produção de OF, comprometendo os controlos de qualidade e segurança, quer pelos efeitos fisiológicos da cafeína consumida por OF ser ainda um tema em estudo.

De forma a colmatar a lacuna científica nesta área, tirou-se partido da influência da cafeína sobre a modulação da atividade do sistema nervoso através do rastreamento da variabilidade da atividade cardíaca. Assim, considerando a era científico-tecnológica em que vivemos, recorreu-se a métodos robustos de processamento de sinal e técnicas de Inteligência Artificial para estudar comparações binárias, a fim de compreender as modalidades café *versus* OF_cafeína. Os resultados das análises individuais revelaram os melhores valores de precisão média para os classificadores de árvore de decisão no treino PCA 100% (50,2%) e *Fine Gaussian* no treino com PCA 95% (72%), para as comparações descafeinado/café e OF_placebo/OF_cafeína, respetivamente. Ainda assim, é importante realçar que existem picos discriminativos de maior amplitude que são camuflados pela análise da precisão média. Analisando as respetivas curvas de precisão conclui-se que, contrariamente ao descafeinado e café, verificaram-se diferenças significativas entre o OF_placebo e o OF_cafeína, nomeadamente na eficiência da rápida dissolução e na taxa de libertação controlada ao longo do tempo. Esta conclusão evidencia que a administração da cafeína através dos OF é realmente uma tecnologia promissora. Entretanto, embora o comportamento das trajetórias das duas curvas de precisão seja muito semelhante entre si, não é possível concluir sobre a discriminação entre o café e o OF_cafeína, uma vez que, o significado dos respetivos valores é distinto. Enquanto que, num dos casos, manifestam-se diferenças significativas tendo o OF_cafeína evidenciando-se em relação ao seu placebo, no caso da comparação descafeinado/café a análise revelou-se comprometedor porque os resultados apontam para que o descafeinado não constitua um verdadeiro placebo do café.

Embora os resultados tenham sido no geral satisfatórios, e o principal objetivo sobre o estudo dos OF tenha sido concretizado, algumas limitações são reconhecidas nesta metodologia. Desta forma, devem ter-se em consideração as sugestões de perspetivas futuras apresentadas:

- Testar o algoritmo numa base de dados maior e mais robusta, para que os resultados possam ter significância estatística. Nomeadamente, deve-se equilibrar o número de mulheres e homens, de forma a solucionar a falta de heterogeneidade de gênero.
- Realizar uma análise individual do poder discriminativo de cada métrica, a fim de perceber quais são aquelas que melhor descrevem o sinal. Seria interessante testar outras métricas.
- Refinar os parâmetros de classificação de cada classificador utilizado.
- Deve-se investir na otimização dos OF.
- Estudaram-se apenas medições de curto prazo de parâmetros cardiovasculares. Seria também essencial investigar os efeitos fisiológicos da cafeína de longo prazo.
- Após as ponderações mencionadas estarem concluídas e, conseqüentemente, toda a metodologia estar mais vigorosa recomenda-se a realização de estudos que comparem as medidas psicofisiológicas com outras modalidades, como a Ressonância Magnética Nuclear, porém mais precisa em relação ao padrão dos agentes farmacológicos e respetivos mecanismos de ação.



Precisão dos Classificadores com PCA=100%

A.1 Classificação Binária Descafeinado/Café

Tabela A.1.1 Precisão da classificação binária descafeinado/café com PCA=100% usando os classificadores de árvore de decisão, análise discriminante, regressão logística e *naïve bayes*.

Análise ao minuto	<i>Fine Tree</i>	<i>Medium Tree</i>	<i>Coarse Tree</i>	<i>Lineaar Discriminant</i>	<i>Logist Regression</i>	<i>Naïve Bayes Gaussiane</i>
1	42,3	42,3	42,3	53,8	53,8	53,8
2	46,2	46,2	46,2	53,8	53,8	42,3
3	46,2	46,2	46,2	30,8	30,8	38,5
4	53,8	53,8	53,8	42,3	42,3	50,0
5	42,3	42,3	42,3	42,3	42,3	42,3
6	50,0	50,0	50,0	46,2	46,2	50,0
7	42,3	42,3	42,3	61,5	61,5	38,5
8	61,5	61,5	61,5	50,0	50,0	50,0
9	57,7	57,7	57,7	30,8	30,8	34,6
10	46,2	46,2	46,2	53,8	53,8	46,2
11	61,5	61,5	61,5	65,4	65,4	61,5
12	46,2	46,2	46,2	50,0	50,0	69,2
13	61,5	61,5	61,5	53,8	53,8	61,5
14	53,8	53,8	53,8	50,0	50,0	46,2
15	61,5	61,5	61,5	61,5	61,5	46,2
16	46,2	46,2	46,2	42,3	42,3	34,6
17	46,2	46,2	46,2	50,0	50,0	50,0
18	38,5	38,5	38,5	53,8	53,8	42,3
19	30,8	30,8	30,8	46,2	46,2	38,5
20	53,8	53,8	53,8	65,4	65,4	57,7
21	69,2	69,2	69,2	42,3	42,3	69,2
22	53,8	53,8	53,8	34,6	34,6	38,5

Continua na próxima página

23	42,3	42,3	42,3	57,7	57,7	50,0
24	53,8	53,8	53,8	38,5	38,5	57,7
25	57,7	57,7	57,7	53,8	53,8	46,2
26	61,5	61,5	61,5	76,9	76,9	50,0
27	34,6	34,6	34,6	23,1	23,1	46,2
28	38,5	38,5	38,5	30,8	30,8	50,0
29	53,8	53,8	53,8	61,5	61,5	57,7
30	42,3	42,3	42,3	42,3	42,3	42,3
31	53,8	53,8	53,8	34,6	24,6	46,2
32	38,5	38,5	38,5	34,6	34,6	34,6
33	53,8	53,8	53,8	19,2	19,2	34,6
34	50,0	50,0	50,0	23,1	23,1	42,3
35	53,8	53,8	53,8	53,8	53,8	61,5
36	57,7	57,7	57,7	46,2	46,2	53,8
37	42,3	42,3	42,3	50,0	50,0	61,5
38	38,5	38,5	38,5	34,6	34,6	46,2
39	50,0	50,0	50,0	46,2	46,2	53,8
40	53,8	53,8	53,8	73,1	73,1	42,3
41	46,2	46,2	46,2	34,6	34,6	19,2
42	65,4	65,4	65,4	80,8	80,8	61,5
43	53,8	53,8	53,8	26,9	26,9	38,5
44	46,2	46,2	46,2	61,5	61,5	57,7
45	57,7	57,7	57,7	61,5	61,5	34,6
46	46,2	46,2	46,2	26,9	26,9	26,9
47	50,0	50,0	50,0	57,7	57,7	57,7
48	69,2	69,2	69,2	73,1	73,1	61,5
49	50,0	50,0	50,0	38,5	38,5	53,8
50	38,5	38,5	38,5	42,3	42,3	30,8
Valor médio	50,2	50,2	50,2	47,7	47,5	47,6

Tabela A.1.2 Precisão da classificação binária descafeinado/café com PCA=100% usando os classificadores SVM.

Análise ao minuto	Linear SVM	Quadratic SVM	Cubic SVM	Fine Gaussian SVM	Medium Gaussian SVM	Coarse Gaussian SVM
1	15,4	46,2	46,2	0,0	0,0	0,0
2	15,4	53,8	53,8	3,8	0,0	0,0
3	23,1	30,8	30,8	0,0	11,5	0,0
4	7,7	42,3	46,2	0,0	0,0	0,0

Continua na próxima página

5	15,4	42,3	42,3	0,0	0,0	0,0
6	23,1	46,2	46,2	0,0	0,0	0,0
7	11,5	57,7	53,8	0,0	0,0	0,0
8	19,2	42,3	46,2	0,0	3,8	0,0
9	15,4	30,8	30,8	3,8	3,8	0,0
10	19,2	53,8	53,8	0,0	0,0	0,0
11	23,1	65,4	65,4	0,0	0,0	0,0
12	15,4	53,8	50,0	0,0	0,0	0,0
13	19,2	50,0	57,7	0,0	0,0	0,0
14	15,4	61,5	57,7	0,0	0,0	0,0
15	19,2	57,7	53,8	0,0	0,0	0,0
16	19,2	42,3	46,2	0,0	0,0	0,0
17	30,8	53,8	53,8	0,0	0,0	0,0
18	15,4	61,5	57,7	0,0	0,0	0,0
19	19,2	46,2	46,2	0,0	0,0	0,0
20	30,8	69,2	69,2	3,8	0,0	0,0
21	30,8	38,5	38,5	0,0	0,0	0,0
22	15,4	34,6	34,6	0,0	3,8	0,0
23	26,9	61,5	57,7	0,0	0,0	0,0
24	26,9	38,5	38,5	0,0	0,0	0,0
25	26,9	53,8	53,8	0,0	0,0	0,0
26	11,5	69,2	65,4	0,0	0,0	0,0
27	15,4	23,1	23,1	0,0	0,0	0,0
28	7,7	30,8	26,9	0,0	0,0	0,0
29	23,1	69,2	69,2	0,0	0,0	0,0
30	23,1	50,0	50,0	0,0	0,0	0,0
31	23,1	34,6	34,6	0,0	0,0	0,0
32	19,2	34,6	34,6	3,8	0,0	0,0
33	7,7	19,2	19,2	0,0	3,8	0,0
34	11,5	23,1	23,1	0,0	0,0	0,0
35	23,1	57,7	61,5	7,7	0,0	0,0
36	23,1	46,2	50,0	3,8	3,8	0,0
37	23,1	50,0	46,2	0,0	0,0	0,0
38	23,1	34,6	38,5	0,0	0,0	0,0
39	26,9	46,2	50,0	0,0	0,0	0,0
40	11,5	61,5	61,5	0,0	0,0	0,0
41	3,8	26,9	30,8	0,0	0,0	0,0
42	15,4	80,8	80,8	0,0	0,0	0,0
43	11,5	26,9	26,9	0,0	7,7	0,0
44	26,9	57,7	57,7	3,8	0,0	0,0

Continua na próxima página

45	19,2	61,5	61,5	0,0	0,0	0,0
46	19,2	26,9	26,9	0,0	7,7	0,0
47	26,9	57,7	57,7	3,8	0,0	0,0
48	34,6	69,2	69,2	3,8	0,0	0,0
49	30,8	42,3	46,2	0,0	0,0	0,0
50	7,7	42,3	34,6	3,8	0,0	0,0
Valor médio	19,4	47,5	47,5	0,8	0,9	0,0

Tabela A.1.3 Precisão da classificação binária descafeinado/café com PCA=100% usando os classificadores KNN.

Análise ao minuto	<i>Fine KNN</i>	<i>Medium KNN</i>	<i>Coarse KNN</i>	<i>Cosine KNN</i>	<i>Cubic KNN</i>	<i>Weighted KNN</i>
1	57,7	50,0	0,0	50,0	50,0	42,3
2	50,0	50,0	0,0	50,0	53,8	53,8
3	30,8	38,5	0,0	38,5	34,6	30,8
4	42,3	50,0	0,0	50,0	46,2	46,2
5	50,0	30,8	0,0	30,8	50,0	42,3
6	42,3	46,2	0,0	46,2	50,0	42,3
7	53,8	46,2	0,0	46,2	53,8	34,6
8	57,7	61,5	0,0	61,5	50,0	53,8
9	46,2	46,2	0,0	46,2	53,8	34,6
10	61,5	46,2	0,0	46,2	46,2	50,0
11	61,5	53,8	0,0	53,8	42,3	53,8
12	57,7	38,5	0,0	38,5	34,6	34,6
13	53,8	57,7	0,0	57,7	57,7	46,2
14	73,1	42,3	0,0	42,3	46,2	53,8
15	61,5	50,0	0,0	50,0	46,2	53,8
16	42,3	34,6	0,0	34,6	46,2	34,6
17	50,0	42,3	0,0	42,3	46,2	46,2
18	46,2	46,2	0,0	46,2	42,3	42,3
19	30,8	50,0	0,0	50,0	53,8	38,5
20	57,7	57,7	0,0	57,7	50,0	69,2
21	50,0	57,7	0,0	57,7	50,0	50,0
22	23,1	42,3	0,0	42,3	34,6	34,6
23	46,2	61,5	0,0	61,5	61,5	65,4
24	46,2	38,5	0,0	38,5	38,5	46,2
25	53,8	50,0	0,0	50,0	42,3	53,8
26	46,2	46,2	0,0	46,2	38,5	53,8

Continua na próxima página

27	26,9	23,1	0,0	23,1	19,2	26,9
28	42,3	26,9	0,0	26,9	26,9	19,2
29	57,7	50,0	0,0	50,0	50,0	50,0
30	57,7	38,5	0,0	38,5	34,6	42,3
31	42,3	46,2	0,0	46,2	50,0	38,5
32	57,7	46,2	0,0	46,2	38,5	42,3
33	30,8	23,1	0,0	23,1	23,1	26,9
34	46,2	19,2	0,0	19,2	34,6	19,2
35	53,8	65,4	0,0	65,4	61,5	53,8
36	42,3	46,2	0,0	46,2	34,6	42,3
37	57,7	50,0	0,0	50,0	26,9	42,3
38	42,3	34,6	0,0	34,6	26,9	30,8
39	50,0	38,5	0,0	38,5	30,8	46,2
40	42,3	61,5	0,0	61,5	54,4	50,0
41	15,4	30,8	0,0	30,8	26,9	23,1
42	53,8	65,4	0,0	65,4	54,4	69,2
43	30,8	15,4	0,0	15,4	23,1	23,1
44	57,7	42,3	0,0	42,3	46,2	38,5
45	38,5	53,8	0,0	53,8	46,2	50,0
46	30,8	19,2	0,0	19,2	19,2	19,2
47	42,3	61,5	0,0	61,5	30,8	53,8
48	50,0	50,0	0,0	50,0	73,1	57,7
49	53,8	57,7	0,0	57,7	53,8	53,8
50	38,5	34,6	0,0	34,6	42,3	30,8
Valor médio	47,1	44,7	0,0	44,7	42,9	43,1

Tabela A.1.4 Precisão da classificação binária descafeinado/café com PCA=100% usando os classificadores *Ensemble*.

Análise ao minuto	<i>Boosted Tress</i>	<i>Bagged Trees</i>	<i>Subspace Discriminant</i>	<i>Subspace KNN</i>	<i>Rusboosted Trees</i>
1	0,0	53,8	53,8	30,8	15,4
2	0,0	53,8	53,8	61,5	19,2
3	0,0	34,6	30,8	38,5	19,2
4	0,0	61,5	42,3	50,0	23,1
5	0,0	65,4	42,3	19,2	7,7
6	0,0	38,5	46,2	50,0	19,2
7	0,0	50,0	61,5	26,9	16,2
8	0,0	46,2	50,0	46,2	26,9

Continua na próxima página

9	0,0	38,5	30,8	38,5	11,5
10	0,0	46,2	53,8	42,3	15,4
11	0,0	42,3	65,4	50,0	34,6
12	0,0	38,5	50,0	34,6	26,9
13	0,0	38,5	57,7	61,5	30,8
14	0,0	73,1	53,8	46,2	34,6
15	0,0	65,4	65,4	46,2	23,1
16	0,0	38,5	42,3	30,8	23,1
17	0,0	38,5	53,8	50,0	38,5
18	0,0	38,5	53,8	34,6	19,2
19	0,0	50,0	46,2	38,5	15,4
20	0,0	42,3	65,4	57,7	23,1
21	0,0	65,4	42,3	65,4	26,9
22	0,0	50,0	34,6	46,2	23,1
23	0,0	69,2	57,7	57,7	19,2
24	0,0	57,7	38,5	38,5	23,1
25	0,0	38,5	53,8	34,6	30,8
26	0,0	57,7	76,9	38,5	42,3
27	0,0	38,5	23,1	26,9	23,1
28	0,0	15,4	30,8	30,8	11,5
29	0,0	50,0	65,4	53,8	30,8
30	0,0	46,2	42,3	57,7	23,1
31	0,0	38,5	34,6	42,3	19,2
32	0,0	53,8	34,6	50,0	19,2
33	0,0	46,2	19,2	38,5	15,4
34	0,0	34,6	23,1	30,8	23,1
35	0,0	34,6	53,8	38,5	15,4
36	0,0	57,7	46,2	42,3	23,1
37	0,0	50,0	46,2	46,2	26,9
38	0,0	38,5	34,6	50,0	30,8
39	0,0	50,0	46,2	46,2	34,6
40	0,0	53,8	73,1	26,9	15,4
41	0,0	42,3	34,6	34,6	15,4
42	0,0	38,5	80,8	61,5	23,1
43	0,0	53,8	26,9	57,7	3,8
44	0,0	73,1	61,5	50,0	26,9
45	0,0	46,2	61,5	30,8	26,9
46	0,0	38,5	26,9	26,9	26,9
47	0,0	34,6	61,5	42,3	19,2
48	0,0	50,0	73,1	50,0	19,2

Continua na próxima página

49	0,0	38,5	38,5	50,0	19,2
50	0,0	50,0	42,3	38,5	46,2
Valor médio	0,0	47,3	48,1	43,2	22,9

A.2 Classificação Binária OF_placebo/OF_cafeína

Tabela A.2.1 Precisão da classificação binária OF_placebo/OF_cafeína com PCA=100% usando os classificadores de árvore de decisão, análise discriminante, regressão logística e naïve bayes.

Análise ao minuto	<i>Fine Tree</i>	<i>Medium Tree</i>	<i>Coarse Tree</i>	<i>Lineaar Discriminant</i>	<i>Logist Regression</i>	<i>Naïve Bayes Gaussiane</i>
1	69,2	69,2	69,2	50,0	50,0	50,0
2	57,7	57,7	57,7	76,9	76,9	50,0
3	50,0	50,0	50,0	61,5	61,5	50,0
4	73,1	73,1	73,1	69,2	69,2	50,0
5	80,8	80,8	80,8	76,9	76,9	50,0
6	73,1	73,1	73,1	73,1	73,1	50,0
7	57,7	57,7	57,7	57,7	57,7	50,0
8	42,3	42,3	42,3	42,3	42,3	50,0
9	76,9	76,9	76,9	76,9	76,9	50,0
10	53,8	53,8	53,8	57,7	57,7	50,0
11	69,2	69,2	69,2	53,8	53,8	50,0
12	73,1	73,1	73,1	69,2	69,2	50,0
13	50,0	50,0	50,0	50,0	50,0	50,0
14	69,2	69,2	69,2	80,8	80,8	50,0
15	69,2	69,2	69,2	61,5	61,5	50,0
16	73,1	73,1	73,1	73,1	73,1	50,0
17	69,2	69,2	69,2	57,7	57,7	50,0
18	50,0	50,0	50,0	69,2	69,2	50,0
19	57,7	57,7	57,7	57,7	57,7	50,0
20	65,4	65,4	65,4	80,8	80,8	50,0
21	76,9	76,9	76,9	73,1	73,1	50,0
22	61,5	61,5	61,5	73,1	73,1	50,0
23	69,2	69,2	69,2	61,5	61,5	50,0
24	65,4	65,4	65,4	80,8	80,8	50,0
25	61,5	61,5	61,5	69,2	69,2	50,0
26	57,7	57,7	57,7	50,0	50,0	50,0

Continua na próxima página

27	69,2	69,2	69,2	61,5	61,5	50,0
28	57,7	57,7	57,7	50,0	50,0	50,0
29	69,2	69,2	69,2	57,7	57,7	50,0
30	69,2	69,2	69,2	46,2	46,2	50,0
31	76,9	76,9	76,9	53,8	53,8	50,0
32	69,2	69,2	69,2	61,5	61,5	50,0
33	57,7	57,7	57,7	50,0	50,0	50,0
34	61,5	61,5	61,5	61,5	61,5	50,0
35	65,4	65,4	65,4	65,4	65,4	50,0
36	73,1	73,1	73,1	69,2	69,2	50,0
37	69,2	69,2	69,2	61,5	61,5	50,0
38	76,9	76,9	76,9	53,8	53,8	50,0
39	61,5	61,5	61,5	57,7	57,7	50,0
40	88,5	88,5	88,5	69,2	69,2	50,0
41	65,4	65,4	65,4	65,4	65,4	50,0
42	65,4	65,4	65,4	65,4	65,4	50,0
43	57,7	57,7	57,7	46,2	46,2	50,0
44	69,2	69,2	69,2	80,8	80,8	50,0
45	73,1	73,1	73,1	69,2	69,2	50,0
46	50,0	50,0	50,0	53,8	53,8	50,0
47	73,1	73,1	73,1	92,3	92,3	50,0
48	57,7	57,7	57,7	46,2	46,2	50,0
49	69,2	69,2	69,2	69,2	69,2	50,0
50	53,8	53,8	53,8	69,2	69,2	50,0
Valor médio	65,5	65,5	65,5	63,6	63,6	50,0

Tabela A.2.2 Precisão da classificação binária OF_placebo/OF_cafeína com PCA=100% usando os classificadores SVM.

Análise ao minuto	Linear SVM	Quadratic SVM	Cubic SVM	Fine Gaussian SVM	Medium Gaussian SVM	Coarse Gaussian SVM
1	42,3	50,0	50,0	23,1	0,0	0,0
2	42,3	50,0	65,4	23,1	0,0	0,0
3	53,8	50,0	65,4	69,2	0,0	0,0
4	50,0	50,0	61,5	23,1	0,0	0,0
5	46,2	50,0	57,7	19,2	0,0	0,0
6	61,5	50,0	61,5	73,1	0,0	0,0
7	61,5	50,0	53,8	76,9	0,0	0,0
8	57,7	50,0	61,5	34,6	0,0	0,0

Continua na próxima página

9	50,0	50,0	76,9	23,1	0,0	0,0
10	57,7	50,0	61,5	69,2	0,0	0,0
11	50,0	50,0	57,7	19,2	0,0	0,0
12	69,2	50,0	53,8	73,1	0,0	0,0
13	38,5	50,0	57,7	69,2	0,0	0,0
14	46,2	50,0	57,7	23,1	0,0	0,0
15	42,3	50,0	53,8	19,2	0,0	0,0
16	65,4	50,0	69,2	69,2	0,0	0,0
17	57,7	50,0	69,2	23,1	0,0	0,0
18	57,7	50,0	61,5	73,1	0,0	0,0
19	57,7	50,0	57,7	73,1	0,0	0,0
20	69,2	50,0	69,2	69,2	0,0	0,0
21	38,5	50,0	50,0	26,9	0,0	0,0
22	61,5	50,0	65,4	23,1	0,0	0,0
23	53,8	50,0	53,8	69,2	0,0	0,0
24	53,8	50,0	73,1	73,1	0,0	0,0
25	46,2	50,0	69,2	76,9	0,0	0,0
26	50,0	50,0	88,5	65,4	0,0	0,0
27	38,5	50,0	57,7	15,4	0,0	0,0
28	65,4	50,0	69,2	65,4	0,0	0,0
29	61,5	50,0	69,2	34,6	0,0	0,0
30	50,0	50,0	73,1	73,1	0,0	0,0
31	50,0	50,0	57,7	69,2	0,0	0,0
32	53,8	50,0	61,5	65,4	0,0	0,0
33	42,3	50,0	73,1	69,2	0,0	0,0
34	53,8	50,0	69,2	19,2	0,0	0,0
35	42,3	50,0	57,7	10,2	0,0	0,0
36	53,8	50,0	61,5	23,1	0,0	0,0
37	61,5	50,0	57,7	69,2	0,0	0,0
38	34,6	50,0	76,9	15,4	0,0	0,0
39	53,8	50,0	65,4	65,4	0,0	0,0
40	50,0	50,0	57,7	19,2	0,0	0,0
41	69,2	50,0	46,2	69,2	0,0	0,0
42	50,0	50,0	61,5	15,4	0,0	0,0
43	57,7	50,0	76,9	26,9	0,0	0,0
44	57,7	50,0	69,2	76,9	0,0	0,0
45	38,5	50,0	57,7	23,1	0,0	0,0
46	42,3	50,0	53,8	19,2	0,0	0,0
47	50,0	50,0	65,4	23,1	0,0	0,0
48	46,2	50,0	53,8	73,1	0,0	0,0

Continua na próxima página

49	57,7	50,0	61,5	73,1	0,0	0,0
50	42,3	50,0	76,9	23,1	0,0	0,0
Valor médio	52,1	50,0	63,1	46,4	0,0	0,0

Tabela A.2.3 Precisão da classificação binária OF_placebo/OF_cafeína com PCA=100% usando os classificadores KNN.

Análise ao minuto	<i>Fine KNN</i>	<i>Medium KNN</i>	<i>Coarse KNN</i>	<i>Cosine KNN</i>	<i>Cubic KNN</i>	<i>Weighted KNN</i>
1	50,0	65,4	0,0	65,4	46,2	65,4
2	50,0	50,0	0,0	42,3	34,6	53,8
3	50,0	46,2	0,0	45,2	19,2	46,2
4	50,0	65,4	0,0	61,5	42,3	65,4
5	50,0	50,0	0,0	50,0	38,5	50,0
6	50,0	46,2	0,0	42,3	26,9	46,2
7	50,0	50,0	0,0	46,2	46,2	50,0
8	50,0	46,2	0,0	46,2	34,6	46,2
9	50,0	53,8	0,0	53,8	23,1	53,8
10	50,0	46,2	0,0	42,3	57,7	46,2
11	50,0	50,0	0,0	50,0	50,0	50,0
12	50,0	50,0	0,0	50,0	50,0	53,8
13	50,0	46,2	0,0	46,2	57,7	46,2
14	50,0	61,5	0,0	61,5	42,3	69,2
15	50,0	50,0	0,0	50,0	30,8	53,8
16	50,0	57,7	0,0	57,7	46,2	57,7
17	50,0	42,3	0,0	42,3	30,8	42,3
18	50,0	46,2	0,0	42,3	65,4	50,0
19	50,0	53,8	0,0	53,8	50,0	53,8
20	50,0	57,7	0,0	57,7	38,5	57,7
21	50,0	53,8	0,0	53,8	26,9	57,7
22	50,0	57,7	0,0	53,8	46,2	57,7
23	50,0	53,8	0,0	53,8	34,6	53,8
24	50,0	46,2	0,0	46,2	26,9	50,0
25	50,0	53,8	0,0	53,8	50,0	53,8
26	50,0	42,3	0,0	42,3	23,1	50,0
27	50,0	61,5	0,0	61,5	26,9	61,5
28	50,0	46,2	0,0	46,2	38,5	46,2
29	50,0	42,3	0,0	42,3	23,1	42,3
30	50,0	38,5	0,0	34,6	38,5	38,5

Continua na próxima página

31	50,0	46,2	0,0	42,3	23,1	50,0
32	50,0	42,3	0,0	38,5	50,0	42,3
33	50,0	38,5	0,0	38,5	50,0	42,3
34	50,0	50,0	0,0	50,0	34,6	50,0
35	50,0	53,8	0,0	53,8	19,2	57,7
36	50,0	50,0	0,0	50,0	42,3	53,8
37	50,0	46,2	0,0	46,2	26,9	53,8
38	50,0	46,2	0,0	46,2	26,9	46,2
39	50,0	46,2	0,0	46,2	34,6	46,2
40	50,0	53,8	0,0	53,8	34,6	53,8
41	50,0	57,7	0,0	50,0	50,0	57,7
42	50,0	50,0	0,0	50,0	50,0	50,0
43	50,0	38,5	0,0	38,5	26,9	42,3
44	50,0	53,8	0,0	53,8	50,0	53,8
45	50,0	50,0	0,0	50,0	50,0	50,0
46	50,0	46,2	0,0	46,2	34,6	46,2
47	50,0	50,0	0,0	50,0	50,0	50,0
48	50,0	46,2	0,0	42,3	23,1	46,2
49	50,0	57,7	0,0	57,7	23,1	57,7
50	50,0	38,5	0,0	38,5	23,1	46,2
Valor médio	50,0	49,9	0,0	48,8	37,8	51,3

Tabela A.2.4 Precisão da classificação binária OF_placebo/OF_cafeína com PCA=100% usando os classificadores *Ensemble*.

Análise ao minuto	<i>Boosted Tress</i>	<i>Bagged Trees</i>	<i>Subspace Discriminant</i>	<i>Subspace KNN</i>	<i>Rusboosted Trees</i>
1	0,0	65,4	50,0	61,5	19,2
2	0,0	46,2	76,9	57,7	23,1
3	0,0	69,2	61,5	50,0	15,4
4	0,0	65,4	69,2	73,1	19,2
5	0,0	57,7	76,9	76,9	26,9
6	0,0	76,9	73,1	69,2	42,3
7	0,0	57,7	57,7	57,7	23,1
8	0,0	61,5	42,3	50,0	3,8
9	0,0	73,1	76,9	57,7	11,5
10	0,0	50,0	53,8	38,5	23,1
11	0,0	53,8	53,8	46,9	26,9
12	0,0	65,4	69,2	73,1	15,4

Continua na próxima página

13	0,0	50,0	50,0	50,0	19,2
14	0,0	53,8	80,8	69,2	19,2
15	0,0	65,4	61,5	61,5	23,1
16	0,0	53,8	69,2	76,9	11,5
17	0,0	65,4	57,7	69,2	26,9
18	0,0	57,7	69,2	65,4	11,5
19	0,0	80,8	57,7	69,2	15,4
20	0,0	53,8	80,8	61,5	19,2
21	0,0	76,9	73,1	76,9	23,1
22	0,0	53,8	73,1	57,7	19,2
23	0,0	57,7	61,5	42,3	7,7
24	0,0	69,2	80,8	57,7	19,2
25	0,0	53,8	69,2	61,5	30,8
26	0,0	38,5	50,0	73,1	0,0
27	0,0	57,7	61,5	30,8	7,7
28	0,0	50,0	50,0	50,0	15,4
29	0,0	65,4	57,7	73,1	26,9
30	0,0	80,8	46,2	65,4	23,1
31	0,0	65,4	53,8	73,1	34,6
32	0,0	65,4	61,5	65,4	11,5
33	0,0	42,3	50,0	50,0	11,5
34	0,0	53,8	61,5	73,1	26,9
35	0,0	53,8	65,4	65,4	34,6
36	0,0	65,4	69,2	69,2	11,5
37	0,0	73,1	61,5	57,7	34,6
38	0,0	69,2	53,8	53,8	34,6
39	0,0	61,5	57,7	57,7	30,8
40	0,0	50,0	69,2	53,8	23,1
41	0,0	69,2	65,4	53,8	30,8
42	0,0	46,2	65,4	73,1	30,8
43	0,0	61,5	46,2	42,3	19,2
44	0,0	61,5	80,8	65,4	38,5
45	0,0	65,4	69,2	61,5	19,2
46	0,0	50,0	53,8	57,7	11,5
47	0,0	73,1	92,3	61,5	19,2
48	0,0	50,0	46,2	46,2	7,7
49	0,0	53,8	65,4	69,2	26,9
50	0,0	61,5	69,2	76,9	11,5
Valor médio	0,0	60,4	63,4	61,0	20,8

Precisão dos Classificadores com PCA=95%

B.1 Classificação Binária Descafeinado/Café

Tabela B.1.1 Precisão da classificação binária descafeinado/café com PCA=95% usando os classificadores de árvore de decisão, análise discriminante, regressão logística e *naïve bayes*.

Análise ao minuto	<i>Fine Tree</i>	<i>Medium Tree</i>	<i>Coarse Tree</i>	<i>Lineaar Discriminant</i>	<i>Logist Regression</i>	<i>Naïve Bayes Gaussiane</i>
1	23,1	23,1	23,1	26,9	23,1	26,9
2	57,7	57,7	57,7	53,8	53,8	53,8
3	42,3	42,3	42,3	42,3	46,2	30,8
4	19,2	19,2	19,2	15,4	15,4	26,9
5	19,2	19,2	19,2	19,2	23,1	26,9
6	26,9	26,9	26,9	42,3	38,5	53,8
7	34,6	34,6	34,6	23,1	26,9	23,1
8	73,1	73,1	73,1	38,5	38,5	42,3
9	46,2	46,2	46,2	38,5	38,5	38,5
10	34,6	34,6	34,6	57,7	53,8	38,5
11	53,8	53,8	53,8	46,2	34,6	50,0
12	53,8	53,8	53,8	53,8	34,6	69,2
13	57,7	57,7	57,7	61,5	50,0	61,5
14	42,3	42,3	42,3	61,5	61,5	26,9
15	65,4	65,4	65,4	57,7	50,0	46,2
16	42,3	42,3	38,5	38,5	34,6	30,8
17	46,2	46,2	46,2	46,2	42,3	50,0
18	30,8	30,8	30,8	34,6	46,2	34,6
19	19,2	19,2	19,2	42,3	46,2	30,8
20	57,7	57,7	57,7	69,2	61,5	73,1
21	65,4	65,4	65,4	50,0	50,0	42,3
22	42,3	42,3	42,3	46,2	42,3	50,0

Continua na próxima página

23	53,8	53,8	53,8	53,8	57,7	57,7
24	30,8	30,8	30,8	42,3	42,3	50,0
25	42,3	42,3	42,3	34,6	46,2	46,2
26	61,5	61,5	61,5	50,0	53,8	53,8
27	42,3	42,3	42,3	19,2	15,4	38,5
28	34,6	34,6	34,6	26,9	42,3	38,5
29	53,8	53,8	53,8	69,2	61,5	57,7
30	46,2	46,2	46,2	53,8	53,8	50,0
31	57,7	57,7	57,7	46,2	53,8	57,7
32	30,8	30,8	30,8	50,0	42,3	57,7
33	50,0	50,0	50,0	30,8	42,3	38,5
34	34,6	34,6	34,6	42,3	38,5	50,0
35	38,5	38,5	38,5	42,3	42,3	30,8
36	65,4	65,4	65,4	53,8	57,7	57,7
37	46,2	46,2	46,2	50,0	53,8	65,4
38	34,6	34,6	34,6	26,9	30,8	19,2
39	57,7	57,7	57,7	46,2	42,3	46,2
40	34,6	34,6	34,6	38,5	34,6	30,8
41	26,9	26,9	26,9	23,1	30,8	23,1
42	61,5	61,5	65,4	69,2	76,9	50,0
43	61,5	61,5	61,5	53,8	50,0	46,2
44	42,3	42,3	42,3	34,6	34,6	42,3
45	61,5	61,5	61,5	50,0	53,8	46,2
46	42,3	42,3	42,3	46,2	50,0	50,0
47	57,7	57,7	57,7	42,3	42,3	46,2
48	73,1	73,1	73,1	53,8	53,8	57,7
49	38,5	38,5	38,5	53,8	46,2	46,2
50	38,5	38,5	38,5	11,5	38,5	19,2
Valor médio	45,5	45,5	45,5	43,6	44,0	44,0

Tabela B.1.2 Precisão da classificação binária descafeinado/café com PCA=95% usando os classificadores SVM.

Análise ao minuto	<i>Linear SVM</i>	<i>Quadratic SVM</i>	<i>Cubic SVM</i>	<i>Fine Gaussian SVM</i>	<i>Medium Gaussian SVM</i>	<i>Coarse Gaussian SVM</i>
1	34,6	30,8	30,8	15,4	0,0	0,0
2	42,3	46,2	53,8	50,0	0,0	0,0
3	50,0	53,8	46,2	15,4	0,0	0,0
4	11,5	11,5	15,4	0,0	0,0	0,0

Continua na próxima página

5	23,1	15,4	23,1	3,8	0,0	0,0
6	46,6	42,3	50,0	30,8	0,0	0,0
7	26,9	30,8	26,9	23,1	0,0	0,0
8	42,3	30,8	34,6	34,6	0,0	0,0
9	26,9	26,9	26,9	15,4	0,0	0,0
10	50,0	57,7	53,8	34,6	0,0	0,0
11	46,2	50,0	42,3	42,3	0,0	0,0
12	57,7	61,5	42,3	19,2	0,0	0,0
13	57,7	42,3	42,3	23,1	0,0	0,0
14	34,6	53,8	53,8	26,9	0,0	0,0
15	53,8	53,8	50,0	30,8	0,0	0,0
16	26,9	34,6	42,3	15,4	0,0	0,0
17	50,0	38,5	38,5	23,1	0,0	0,0
18	34,6	30,8	34,6	19,2	0,0	0,0
19	30,8	34,6	46,2	19,2	0,0	0,0
20	65,4	65,4	65,4	42,3	0,0	0,0
21	50,0	53,8	53,8	42,3	0,0	0,0
22	30,8	46,2	34,6	3,8	0,0	0,0
23	42,3	57,7	57,7	38,5	0,0	0,0
24	42,3	46,2	42,3	34,6	0,0	0,0
25	34,6	26,9	30,8	19,2	0,0	0,0
26	50,0	46,2	42,3	50,0	0,0	0,0
27	19,2	11,5	19,2	3,8	0,0	0,0
28	11,5	26,9	34,6	23,1	0,0	0,0
29	69,2	73,1	57,7	46,2	0,0	0,0
30	57,7	61,5	57,7	46,2	0,0	0,0
31	46,2	53,8	50,0	46,2	0,0	0,0
32	46,2	50,0	42,3	30,8	0,0	0,0
33	23,1	30,8	30,8	15,4	0,0	0,0
34	50,0	42,3	38,5	3,8	0,0	0,0
35	30,8	42,3	42,3	26,9	0,0	0,0
36	42,3	46,2	57,7	38,5	0,0	0,0
37	50,0	50,0	57,7	50,0	0,0	0,0
38	15,4	15,4	30,8	11,5	0,0	0,0
39	46,2	46,2	34,6	26,9	0,0	0,0
40	38,5	30,8	30,8	30,8	0,0	0,0
41	23,1	30,8	23,1	11,5	0,0	0,0
42	69,2	69,2	65,4	57,7	3,8	0,0
43	46,2	50,0	46,2	23,1	0,0	0,0
44	26,9	42,3	53,8	42,3	0,0	0,0

Continua na próxima página

45	46,2	50,0	46,2	26,9	0,0	0,0
46	46,2	30,8	30,8	19,2	0,0	0,0
47	46,2	42,3	50,0	30,8	0,0	0,0
48	46,2	50,0	50,0	42,3	0,0	0,0
49	46,2	50,0	53,8	34,6	0,0	0,0
50	11,5	19,2	19,2	11,5	0,0	0,0
Valor médio	40,3	42,1	42,1	27,5	0,1	0,0

Tabela B.1.3 Precisão da classificação binária descafeinado/café com PCA=95% usando os classificadores KNN.

Análise ao minuto	<i>Fine KNN</i>	<i>Medium KNN</i>	<i>Coarse KNN</i>	<i>Cosine KNN</i>	<i>Cubic KNN</i>	<i>Weighted KNN</i>
1	42,3	38,5	0,0	38,5	42,3	26,9
2	46,2	57,7	0,0	46,2	53,8	46,2
3	38,5	38,5	0,0	42,3	50,0	34,6
4	38,5	23,1	0,0	19,2	19,2	19,2
5	30,8	11,5	0,0	30,8	15,4	11,5
6	38,5	42,3	0,0	34,6	38,5	53,8
7	38,5	23,1	0,0	30,8	23,1	26,9
8	61,5	38,5	0,0	38,5	46,2	38,5
9	46,2	42,3	0,0	19,2	38,5	30,8
10	50,0	42,3	0,0	38,5	38,5	50,0
11	57,7	42,3	0,0	50,0	38,5	42,3
12	42,3	50,0	0,0	42,3	42,3	50,0
13	50,0	46,2	0,0	42,3	42,3	46,2
14	38,5	34,6	0,0	42,3	38,5	38,5
15	61,5	57,7	0,0	46,2	46,2	57,7
16	53,8	34,6	0,0	26,9	42,3	46,2
17	38,5	53,8	0,0	50,0	46,2	46,2
18	42,3	46,2	0,0	23,1	46,2	42,3
19	42,3	30,8	0,0	42,3	42,3	34,6
20	57,7	53,8	0,0	65,4	53,8	57,7
21	53,8	38,5	0,0	38,5	38,5	42,3
22	30,8	50,0	0,0	42,3	38,5	38,5
23	50,0	50,0	0,0	50,0	61,5	65,4
24	50,0	30,8	0,0	53,8	26,9	38,5
25	50,0	34,6	0,0	42,3	38,5	30,8
26	50,0	50,0	0,0	42,3	46,2	50,0

Continua na próxima página

27	30,8	23,1	0,0	26,9	30,8	23,1
28	42,3	34,6	0,0	26,9	38,5	26,9
29	65,4	38,5	0,0	53,8	50,0	50,0
30	57,7	53,8	0,0	53,8	57,7	53,8
31	61,5	38,5	0,0	46,2	38,6	50,0
32	53,8	46,2	0,0	53,8	38,5	34,6
33	26,9	23,1	0,0	42,3	23,1	38,5
34	30,8	34,6	0,0	34,6	26,9	26,9
35	34,6	38,5	0,0	46,2	34,6	34,6
36	57,7	46,2	0,0	46,2	46,2	54,8
37	50,0	61,6	0,0	73,1	61,5	57,7
38	42,3	30,8	0,0	19,2	30,8	23,1
39	34,6	50,0	0,0	46,2	50,0	42,3
40	34,6	38,5	0,0	46,2	38,5	34,6
41	38,5	26,9	0,0	30,8	30,8	26,9
42	57,7	61,5	0,0	61,5	73,1	53,8
43	50,0	46,2	0,0	34,6	30,8	30,8
44	46,2	42,3	0,0	42,3	34,6	46,2
45	38,5	46,2	0,0	46,2	53,8	34,6
46	42,3	38,5	0,0	38,5	46,2	38,5
47	34,6	23,1	0,0	50,0	30,8	34,6
48	57,7	42,3	0,0	42,3	53,8	50,0
49	50,0	42,3	0,0	38,5	38,5	42,3
50	34,6	23,1	0,0	26,9	34,6	15,4
Valor médio	45,5	40,2	0,0	41,3	40,9	39,8

Tabela B.1.4 Precisão da classificação binária descafeinado/café com PCA=95% usando os classificadores *Ensemble*.

Análise ao minuto	<i>Boosted Tress</i>	<i>Bagged Trees</i>	<i>Subspace Discriminant</i>	<i>Subspace KNN</i>	<i>Rusboosted Trees</i>
1	34,6	26,9	15,4	15,4	34,6
2	61,5	53,8	57,7	19,2	61,5
3	30,8	42,3	42,3	19,2	30,8
4	15,4	15,4	53,8	23,1	15,4
5	26,9	19,2	23,1	26,9	26,9
6	46,2	42,3	42,3	19,2	46,2
7	53,8	23,1	19,2	42,3	53,8
8	57,7	26,9	50,0	26,9	57,7

Continua na próxima página

9	26,9	38,5	30,8	15,4	26,9
10	65,4	61,5	42,3	30,8	65,4
11	53,8	46,2	53,8	26,9	53,8
12	65,4	53,8	30,8	26,9	65,4
13	50,0	61,5	61,5	26,9	50,0
14	57,7	53,8	42,3	30,8	57,7
15	61,5	57,7	42,3	30,8	61,5
16	34,6	38,5	38,5	26,9	34,6
17	46,2	46,2	46,2	23,1	46,2
18	23,1	34,6	42,3	15,4	23,1
19	42,3	42,3	34,6	11,5	42,3
20	73,1	69,2	73,1	15,4	73,1
21	73,1	53,8	61,5	34,6	73,1
22	42,3	46,2	42,3	30,8	42,3
23	53,8	53,8	42,3	15,4	53,8
24	30,8	42,3	38,5	11,5	30,8
25	53,8	34,6	30,8	30,8	53,8
26	46,2	53,8	43,6	15,4	46,2
27	30,8	19,2	30,8	34,6	30,8
28	38,5	26,9	34,6	26,9	38,5
29	53,8	65,4	53,8	34,6	53,8
30	38,5	57,7	50,0	7,7	38,5
31	61,5	46,2	50,0	23,1	61,5
32	50,0	50,0	38,5	11,5	50,0
33	50,0	30,8	30,8	30,8	50,0
34	38,5	42,3	30,8	34,6	38,5
35	26,9	42,3	34,6	11,5	26,9
36	65,4	53,8	42,3	30,8	65,4
37	46,2	50,0	46,2	26,9	46,2
38	34,6	23,1	34,6	23,1	34,6
39	34,6	46,2	46,2	15,4	34,6
40	38,5	38,5	26,9	11,5	38,5
41	42,3	23,1	38,5	34,6	42,3
42	38,5	65,4	53,8	19,2	38,5
43	42,3	53,8	53,8	50,0	42,3
44	50,0	34,6	42,3	7,7	50,0
45	23,1	53,8	34,6	26,9	23,1
46	42,3	46,2	30,8	34,6	42,3
47	46,2	42,3	42,3	19,2	46,2
48	50,0	53,8	57,7	30,8	50,0

Continua na próxima página

49	42,3	53,8	46,2	26,9	42,3
50	26,9	11,5	42,3	19,2	26,9
Valor médio	44,8	43,4	41,9	24,1	44,8

B.2 Classificação Binária OF_placebo/OF_cafeína

Tabela B.2.1 Precisão da classificação binária OF_placebo/OF_cafeína com PCA=95% usando os classificadores de árvore de decisão, análise discriminante, regressão logística e naïve bayes.

Análise ao minuto	<i>Fine Tree</i>	<i>Medium Tree</i>	<i>Coarse Tree</i>	<i>Lineaar Discriminant</i>	<i>Logist Regression</i>	<i>Naïve Bayes Gaussiane</i>
1	57,7	57,7	57,7	53,8	50,0	50,0
2	57,7	57,7	57,7	57,7	53,8	65,4
3	57,7	57,7	57,7	50,0	53,8	84,6
4	73,1	73,1	73,1	73,1	69,2	69,2
5	80,8	80,8	80,8	65,4	73,1	65,4
6	73,1	73,1	73,1	65,4	69,2	80,8
7	46,2	46,2	46,2	65,4	65,4	57,7
8	57,7	57,7	57,7	46,2	50,0	65,4
9	76,9	76,9	76,9	76,9	84,6	80,8
10	50,0	50,0	50,0	57,7	57,7	65,4
11	69,2	69,2	69,2	57,7	61,5	57,7
12	61,5	61,5	61,5	76,9	80,8	61,5
13	65,4	65,4	65,4	61,5	61,5	69,2
14	69,2	69,2	69,2	80,8	80,8	73,1
15	65,4	65,4	65,4	76,9	65,4	53,8
16	73,1	73,1	73,1	73,1	69,2	73,1
17	61,5	61,5	61,5	57,7	53,8	73,1
18	53,8	53,8	53,8	46,2	53,8	65,4
19	50,0	50,0	50,0	53,8	53,8	46,2
20	65,4	65,4	65,4	80,8	80,8	69,2
21	76,9	76,9	76,9	69,2	69,2	84,6
22	69,2	69,2	69,2	73,1	73,1	65,4
23	73,1	73,1	73,1	65,4	65,4	61,5
24	57,7	57,7	57,7	69,2	61,5	65,4
25	53,8	53,8	53,8	61,5	61,5	57,7
26	57,7	57,7	57,7	50,0	69,2	69,2

Continua na próxima página

27	69,2	69,2	69,2	50,0	46,2	57,7
28	57,7	57,7	57,7	57,7	61,5	61,5
29	61,5	61,5	61,5	73,1	88,5	65,4
30	57,7	57,7	57,7	42,3	42,3	61,5
31	46,2	46,2	46,2	57,7	73,1	65,9
32	61,5	61,5	61,5	57,7	61,5	73,1
33	76,9	76,9	76,9	65,4	61,5	73,1
34	76,9	76,9	76,9	61,5	73,1	73,1
35	61,5	61,5	61,5	73,1	73,1	73,1
36	73,1	73,1	73,1	76,9	76,9	69,2
37	69,2	69,2	69,2	65,4	69,2	65,4
38	84,6	84,6	84,6	61,5	61,5	69,2
39	50,0	50,0	50,0	69,2	65,4	69,2
40	69,2	69,2	69,2	57,7	61,5	53,8
41	57,7	57,7	57,7	76,9	69,2	84,6
42	73,1	73,1	73,1	61,5	69,2	69,2
43	69,2	69,2	69,2	42,3	53,8	57,7
44	76,9	76,9	76,9	73,1	80,8	73,1
45	50,0	50,0	50,0	46,2	57,7	46,2
46	61,5	61,5	61,5	61,5	61,5	69,2
47	73,1	73,1	73,1	88,5	88,5	80,8
48	65,4	65,4	65,4	57,7	61,5	57,7
49	65,4	65,4	65,4	69,2	69,2	73,1
50	53,8	53,8	53,8	65,4	76,9	69,2
Valor médio	64,3	64,3	64,3	63,5	65,8	66,9

Tabela B.2.2 Precisão da classificação binária OF_placebo/OF_cafeína com PCA=95% usando os classificadores SVM.

Análise ao minuto	<i>Linear SVM</i>	<i>Quadratic SVM</i>	<i>Cubic SVM</i>	<i>Fine Gaussian SVM</i>	<i>Medium Gaussian SVM</i>	<i>Coarse Gaussian SVM</i>
1	50,0	50,0	53,8	69,2	0,0	0,0
2	53,8	61,5	61,5	69,2	0,0	0,0
3	50,0	61,5	46,2	65,4	0,0	0,0
4	69,2	69,2	69,2	73,1	0,0	0,0
5	61,5	73,1	76,9	76,9	0,0	0,0
6	69,2	76,9	80,8	76,9	0,0	0,0
7	69,2	65,4	57,7	69,2	0,0	0,0
8	42,3	57,7	46,2	65,4	0,0	0,0

Continua na próxima página

9	76,9	76,9	69,2	80,8	0,0	0,0
10	53,8	57,7	50,0	69,2	0,0	0,0
11	53,8	46,2	57,7	69,2	0,0	0,0
12	76,9	73,1	73,1	76,9	0,0	0,0
13	50,0	61,5	50,0	73,1	0,0	0,0
14	80,8	73,1	69,2	76,9	0,0	0,0
15	69,2	61,5	65,4	69,2	0,0	0,0
16	69,2	69,2	61,5	76,9	3,8	0,0
17	65,4	61,5	61,5	65,4	0,0	0,0
18	57,7	53,8	53,8	73,1	0,0	0,0
19	46,2	53,8	53,8	73,1	0,0	0,0
20	76,9	80,8	80,8	73,1	0,0	0,0
21	69,2	65,4	69,2	69,2	0,0	0,0
22	69,2	69,2	69,2	69,2	0,0	0,0
23	61,5	65,4	65,4	61,5	0,0	0,0
24	69,2	61,5	69,2	73,1	0,0	0,0
25	57,7	61,5	61,5	69,2	0,0	0,0
26	46,2	53,8	53,8	76,9	0,0	0,0
27	46,2	50,0	50,0	69,2	3,8	0,0
28	53,8	57,7	53,8	65,4	0,0	0,0
29	53,8	65,4	76,9	73,1	0,0	0,0
30	42,3	53,8	53,8	73,1	0,0	0,0
31	73,1	50,0	46,2	61,5	73,1	0,0
32	57,7	61,5	61,5	76,9	0,0	0,0
33	65,4	57,7	46,2	76,9	0,0	0,0
34	57,7	53,8	65,4	73,1	0,0	0,0
35	73,1	73,1	69,2	73,1	0,0	0,0
36	65,4	65,4	61,5	69,2	0,0	0,0
37	65,4	65,4	69,2	76,9	0,0	0,0
38	57,7	69,2	69,2	76,9	3,8	0,0
39	61,5	53,8	53,8	69,2	0,0	0,0
40	50,0	57,7	57,7	69,2	0,0	0,0
41	69,2	76,9	76,9	69,2	3,8	0,0
42	57,7	65,4	73,1	76,9	3,8	0,0
43	42,3	50,0	53,8	69,2	0,0	0,0
44	73,1	76,9	73,1	76,9	3,8	0,0
45	42,3	42,3	42,3	73,1	0,0	0,0
46	65,4	69,2	50,0	69,2	3,8	0,0
47	88,5	84,6	80,8	84,6	0,0	0,0
48	61,5	57,7	53,8	65,4	0,0	0,0

Continua na próxima página

49	69,2	65,4	65,4	80,8	0,0	0,0
50	65,4	53,8	65,4	69,2	0,0	0,0
Valor médio	61,5	62,8	61,9	72,0	2,0	0,0

Tabela B.2.3 Precisão da classificação binária OF_placebo/OF_cafeína com PCA=95% usando os classificadores KNN.

Análise ao minuto	<i>Fine KNN</i>	<i>Medium KNN</i>	<i>Coarse KNN</i>	<i>Cosine KNN</i>	<i>Cubic KNN</i>	<i>Weighted KNN</i>
1	46,2	50,0	0,0	65,4	50,0	50,0
2	65,4	50,0	0,0	61,5	50,0	50,0
3	46,2	50,0	0,0	61,5	50,0	50,0
4	73,1	50,0	0,0	73,1	50,0	50,0
5	80,8	50,0	0,0	69,2	50,0	50,0
6	73,1	50,0	0,0	73,1	50,0	50,0
7	65,4	50,0	0,0	65,4	50,0	46,2
8	53,8	50,0	0,0	65,4	50,0	46,2
9	65,4	50,0	0,0	73,1	50,0	50,0
10	50,0	50,0	0,0	57,7	50,0	50,0
11	57,7	50,0	0,0	57,7	50,0	50,0
12	80,8	50,0	0,0	65,4	50,0	46,2
13	57,7	50,0	0,0	61,5	50,0	50,0
14	57,7	50,0	0,0	69,2	50,0	50,0
15	65,4	50,0	0,0	65,4	50,0	46,2
16	65,4	46,2	0,0	61,5	50,0	46,2
17	73,1	50,0	0,0	53,8	50,0	46,2
18	46,2	50,0	0,0	61,5	46,2	50,0
19	65,4	50,0	0,0	53,8	50,0	50,0
20	61,5	50,0	0,0	69,2	50,0	50,0
21	69,2	50,0	0,0	84,6	50,0	50,0
22	69,2	50,0	0,0	76,9	50,0	53,8
23	57,7	50,0	0,0	65,4	50,0	50,0
24	53,8	50,0	0,0	76,9	50,0	53,8
25	69,2	50,0	0,0	65,4	50,0	50,0
26	61,6	50,0	0,0	65,4	50,0	53,8
27	46,2	50,0	0,0	61,5	50,0	50,0
28	46,2	50,0	0,0	80,8	50,0	50,0
29	65,4	50,0	0,0	76,9	50,0	50,0
30	65,4	50,0	0,0	57,7	50,0	50,0

Continua na próxima página

31	61,5	46,2	0,0	61,5	42,3	53,8
32	80,8	50,0	0,0	73,1	50,0	50,0
33	46,2	50,0	0,0	73,1	50,0	50,0
34	65,4	50,0	0,0	65,4	50,0	50,0
35	69,2	50,0	0,0	88,5	50,0	50,0
36	69,2	50,0	0,0	69,2	50,0	50,0
37	57,7	50,0	0,0	69,2	50,0	50,0
38	73,1	53,8	0,0	57,7	53,8	53,8
39	53,8	50,0	0,0	53,8	50,0	50,0
40	50,0	50,0	0,0	57,7	50,0	50,0
41	61,5	50,0	0,0	80,8	50,0	50,0
42	73,1	50,0	0,0	61,5	50,0	50,0
43	53,8	50,0	0,0	57,7	50,0	50,0
44	73,1	50,0	0,0	80,8	50,0	46,2
45	53,8	50,0	0,0	53,8	50,0	50,0
46	65,4	50,0	0,0	61,5	53,8	50,0
47	73,1	50,0	0,0	76,9	50,0	50,0
48	46,2	50,0	0,0	73,1	50,0	53,8
49	73,1	50,0	0,0	69,2	50,0	50,0
50	57,7	50,0	0,0	69,2	50,0	50,0
Valor médio	62,2	49,9	0,0	67,0	49,9	49,9

Tabela B.2.4 Precisão da classificação binária OF_placebo/OFF_cafeína com PCA=95% usando os classificadores *Ensemble*.

Análise ao minuto	<i>Boosted Tress</i>	<i>Bagged Trees</i>	<i>Subspace Discriminant</i>	<i>Subspace KNN</i>	<i>Rusboosted Trees</i>
1	0,0	65,4	53,8	65,4	19,2
2	0,0	65,4	57,7	61,5	11,5
3	0,0	61,5	53,8	42,3	34,6
4	0,0	80,8	69,2	76,9	3,8
5	0,0	69,2	65,4	73,1	11,5
6	0,0	65,4	65,4	65,4	23,1
7	0,0	53,8	65,4	61,5	30,8
8	0,0	57,7	46,2	53,8	30,8
9	0,0	80,8	76,9	65,4	0,0
10	0,0	61,5	61,5	46,2	30,8
11	0,0	53,8	57,7	46,2	26,9
12	0,0	73,1	76,9	73,1	19,2
Continua na próxima página					

13	0,0	69,2	61,5	50,0	34,6
14	0,0	65,4	80,8	61,5	15,4
15	0,0	73,1	73,1	61,5	30,8
16	0,0	53,8	69,2	69,2	23,1
17	0,0	61,5	57,7	69,2	19,2
18	0,0	65,4	46,2	65,4	23,1
19	0,0	57,7	53,8	61,5	7,7
20	0,0	76,9	80,8	73,1	19,2
21	0,0	57,7	69,2	73,1	11,5
22	0,0	50,0	76,9	57,7	26,9
23	0,0	53,8	65,4	38,5	19,2
24	0,0	73,1	69,2	53,8	30,8
25	0,0	65,4	61,1	76,9	38,5
26	0,0	73,1	50,0	65,4	30,8
27	0,0	73,1	46,2	34,6	34,6
28	0,0	61,5	57,7	46,2	23,1
29	0,0	73,1	76,9	65,4	42,3
30	0,0	65,4	42,3	76,9	30,8
31	0,0	53,8	53,8	57,7	23,1
32	0,0	46,2	57,7	73,1	19,2
33	0,0	53,8	65,4	53,8	3,8
34	0,0	57,7	61,5	73,1	15,4
35	0,0	57,7	73,1	65,4	30,8
36	0,0	65,4	80,8	65,4	23,1
37	0,0	76,9	65,4	61,5	15,4
38	0,0	61,5	61,5	53,8	23,1
39	0,0	65,4	69,2	57,7	30,8
40	0,0	61,5	57,7	57,7	30,8
41	0,0	73,1	76,9	65,4	38,5
42	0,0	73,1	61,5	69,2	26,9
43	0,0	65,4	46,2	53,8	26,9
44	0,0	69,2	73,1	65,4	34,6
45	0,0	65,4	42,3	57,7	19,2
46	0,0	61,5	65,4	53,8	15,4
47	0,0	73,1	88,5	65,4	15,4
48	0,0	80,8	61,5	46,2	23,1
49	0,0	65,4	69,2	69,2	15,4
50	0,0	53,8	65,4	65,4	23,1
Valor médio	0,0	64,8	63,7	61,2	23,2



Precisão dos Classificadores com PCA=80%

C.1 Classificação Binária Descafeinado/Café

Tabela C.1.1 Precisão da classificação binária descafeinado/café com PCA=80% usando os classificadores de árvore de decisão, análise discriminante, regressão logística e *naïve bayes*.

Análise ao minuto	<i>Fine Tree</i>	<i>Medium Tree</i>	<i>Coarse Tree</i>	<i>Lineaar Discriminant</i>	<i>Logist Regression</i>	<i>Naïve Bayes Gaussiane</i>
1	42,3	42,3	42,3	26,9	26,9	19,2
2	26,9	26,9	30,8	38,5	42,3	42,3
3	34,6	34,6	38,5	38,5	38,5	30,8
4	38,5	38,5	38,5	30,8	23,1	42,3
5	38,5	38,5	42,3	34,6	34,6	26,9
6	53,8	53,8	53,8	61,5	61,5	50,0
7	26,9	26,9	26,9	19,2	23,1	19,2
8	57,7	57,7	57,7	30,8	30,8	34,6
9	42,3	42,3	42,3	38,5	50,0	42,3
10	38,5	38,5	38,5	26,9	30,8	23,1
11	65,4	65,4	61,5	34,6	38,5	46,2
12	46,2	46,2	46,2	26,9	23,1	38,5
13	53,8	53,8	53,8	73,1	69,2	76,9
14	38,5	38,5	38,5	34,6	30,8	26,9
15	69,2	69,2	69,2	34,6	42,3	42,3
16	38,5	38,5	38,5	53,8	50,0	42,3
17	53,8	53,8	53,8	61,5	53,8	53,8
18	26,9	26,9	26,9	38,5	50,0	34,6
19	50,0	50,0	50,0	26,9	30,8	19,2
20	42,3	42,3	42,3	30,8	42,3	38,5
21	50,0	50,0	50,0	38,5	28,5	38,5
22	42,3	42,3	42,3	50,0	46,2	42,3

Continua na próxima página

23	61,5	61,5	61,5	61,5	53,8	61,5
24	50,0	50,0	50,0	46,2	50,0	53,8
25	42,3	42,3	42,3	38,5	42,3	53,8
26	34,6	34,6	34,6	50,0	50,0	53,8
27	19,2	19,2	19,2	15,4	15,4	46,2
28	46,2	46,2	46,2	30,8	30,8	38,5
29	34,6	34,6	34,6	42,3	53,8	50,0
30	42,3	42,3	42,3	50,0	38,5	53,8
31	42,3	42,3	42,3	57,7	50,0	53,8
32	46,2	46,2	46,2	38,5	38,5	61,5
33	46,2	46,2	46,2	26,9	23,1	38,5
34	42,3	42,3	42,3	42,3	42,3	42,3
35	34,6	34,6	34,6	26,9	38,5	15,4
36	65,4	65,4	65,4	61,5	69,2	57,7
37	34,6	34,6	34,6	46,2	53,8	46,2
38	46,2	46,2	46,2	38,5	38,5	34,6
39	57,7	57,7	57,7	50,0	50,0	57,7
40	38,5	38,5	38,5	34,6	38,5	34,6
41	46,2	46,2	46,2	30,8	26,9	26,9
42	50,0	50,0	53,8	61,5	65,4	57,7
43	69,2	69,2	69,2	42,3	38,5	57,7
44	42,3	42,3	42,3	38,5	38,5	46,2
45	38,5	38,5	38,5	53,8	53,8	38,5
46	42,3	42,3	42,3	61,5	53,8	50,0
47	38,5	38,5	38,5	34,6	38,5	34,6
48	57,7	57,7	57,7	50,0	50,0	46,2
49	46,2	46,2	46,2	53,8	57,7	57,7
50	50,0	50,0	50,0	23,1	23,1	34,6
Valor médio	44,9	44,9	45,1	41,2	41,8	42,7

Tabela C.1.2 Precisão da classificação binária descafeinado/café com PCA=80% usando os classificadores SVM.

Análise ao minuto	<i>Linear SVM</i>	<i>Quadratic SVM</i>	<i>Cubic SVM</i>	<i>Fine Gaussian SVM</i>	<i>Medium Gaussian SVM</i>	<i>Coarse Gaussian SVM</i>
1	23,1	34,6	38,5	7,7	0,0	0,0
2	30,8	53,8	46,2	46,2	0,0	0,0
3	61,5	38,5	30,8	38,5	0,0	0,0
4	15,4	42,3	38,5	0,0	0,0	0,0

Continua na próxima página

5	26,9	30,8	34,6	3,8	0,0	0,0
6	61,5	53,8	57,7	57,7	0,0	0,0
7	15,4	15,4	19,2	0,0	0,0	0,0
8	26,9	42,3	42,3	38,5	0,0	0,0
9	26,9	38,5	50,0	30,8	0,0	0,0
10	23,1	30,8	38,5	19,2	0,0	0,0
11	30,8	38,5	42,3	42,3	0,0	0,0
12	38,5	46,2	46,2	30,8	0,0	0,0
13	50,0	65,4	61,5	61,5	0,0	0,0
14	38,5	30,8	34,6	30,8	0,0	0,0
15	23,1	38,5	53,8	38,5	0,0	0,0
16	61,5	42,3	34,6	30,8	0,0	0,0
17	65,4	57,7	50,0	57,7	0,0	0,0
18	34,6	34,6	34,6	26,9	0,0	0,0
19	19,2	26,9	26,9	23,1	0,0	0,0
20	30,8	34,6	30,8	34,6	0,0	0,0
21	30,8	42,3	46,2	28,5	0,0	0,0
22	46,2	42,3	34,6	30,8	0,0	0,0
23	65,4	61,5	42,3	50,0	0,0	0,0
24	34,6	42,3	46,2	30,8	0,0	0,0
25	34,6	46,2	38,5	23,1	0,0	0,0
26	50,0	30,8	46,2	36,9	0,0	0,0
27	15,4	26,9	23,1	3,8	0,0	0,0
28	15,4	26,9	30,8	23,1	0,0	0,0
29	50,0	50,0	50,0	46,2	0,0	0,0
30	42,3	46,2	42,3	46,2	0,0	0,0
31	65,4	50,0	46,2	42,3	0,0	0,0
32	38,5	53,8	38,5	30,8	0,0	0,0
33	30,8	7,7	23,1	3,8	0,0	0,0
34	42,3	42,3	50,0	30,8	0,0	0,0
35	15,4	30,8	38,5	19,2	0,0	0,0
36	57,7	57,7	53,8	50,0	0,0	0,0
37	46,2	50,0	42,3	46,2	0,0	0,0
38	34,6	46,2	38,5	23,1	0,0	0,0
39	38,5	38,5	46,2	42,3	0,0	0,0
40	30,8	23,1	26,9	19,2	0,0	0,0
41	23,1	23,1	26,9	19,2	0,0	0,0
42	65,4	46,2	34,6	46,2	3,8	0,0
43	46,2	50,0	53,8	42,3	0,0	0,0
44	46,3	57,7	38,5	23,1	0,0	0,0

Continua na próxima página

45	38,5	42,3	42,3	26,9	0,0	0,0
46	57,7	65,4	57,7	53,8	0,0	0,0
47	30,8	30,8	34,6	23,1	0,0	0,0
48	46,2	46,2	53,8	46,2	0,0	0,0
49	50,0	50,0	57,7	46,2	0,0	0,0
50	23,1	26,9	38,5	15,4	0,0	0,0
Valor médio	38,3	41,0	41,1	31,8	0,1	0,0

Tabela C.1.3 Precisão da classificação binária descafeinado/café com PCA=80% usando os classificadores KNN.

Análise ao minuto	<i>Fine KNN</i>	<i>Medium KNN</i>	<i>Coarse KNN</i>	<i>Cosine KNN</i>	<i>Cubic KNN</i>	<i>Weighted KNN</i>
1	26,9	42,3	0,0	38,5	42,3	30,8
2	42,3	42,3	0,0	53,8	46,2	42,3
3	30,8	38,5	0,0	34,6	38,5	46,2
4	46,2	30,8	0,0	38,5	26,9	38,5
5	19,2	30,8	0,0	26,9	38,5	23,1
6	53,8	42,3	0,0	57,7	46,2	50,0
7	34,6	11,5	0,0	15,4	15,4	15,4
8	50,0	46,2	0,0	23,1	46,2	50,0
9	50,0	46,2	0,0	42,3	53,8	38,5
10	46,2	23,1	0,0	38,5	34,6	11,5
11	53,8	38,5	0,0	30,8	46,2	46,2
12	46,2	38,5	0,0	26,9	46,2	46,2
13	65,4	69,2	0,0	61,5	57,7	61,5
14	42,3	42,3	0,0	38,5	38,5	38,5
15	57,7	42,3	0,0	46,2	42,3	42,3
16	46,2	34,6	0,0	34,6	26,9	38,5
17	57,7	57,7	0,0	38,5	53,8	61,5
18	38,5	50,0	0,0	34,6	50,0	38,5
19	34,6	34,6	0,0	34,6	30,8	30,8
20	50,0	42,3	0,0	42,3	38,5	42,3
21	42,3	42,3	0,0	38,5	61,5	50,0
22	38,5	38,5	0,0	50,0	30,8	30,8
23	53,8	61,5	0,0	50,0	53,8	46,2
24	46,2	57,7	0,0	50,0	38,5	38,5
25	50,0	42,3	0,0	50,0	38,5	34,6
26	42,3	42,3	0,0	30,8	50,0	42,3

Continua na próxima página

27	15,4	38,5	0,0	34,6	34,6	26,9
28	34,6	26,9	0,0	23,1	30,8	34,6
29	65,4	42,3	0,0	57,7	46,2	57,7
30	46,2	50,0	0,0	50,0	53,8	53,8
31	46,2	53,8	0,0	53,8	46,2	50,0
32	26,9	38,5	0,0	46,2	38,5	30,8
33	34,6	30,8	0,0	23,1	30,8	23,1
34	42,3	26,9	0,0	34,6	23,1	34,6
35	46,2	23,1	0,0	30,8	26,9	23,1
36	34,6	42,3	0,0	46,2	46,2	53,8
37	53,8	46,2	0,0	46,2	53,8	38,5
38	34,6	57,7	0,0	46,2	57,7	42,3
39	42,3	34,6	0,0	42,3	34,6	50,0
40	26,9	30,8	0,0	38,5	34,6	30,8
41	46,2	38,5	0,0	42,3	46,3	26,9
42	42,3	42,3	0,0	46,2	50,0	46,2
43	50,0	30,8	0,0	50,0	46,2	34,6
44	50,0	38,5	0,0	34,6	42,3	38,5
45	42,3	46,2	0,0	46,2	50,0	46,2
46	57,7	50,0	0,0	38,5	50,0	50,0
47	38,5	38,5	0,0	26,9	26,9	30,8
48	46,2	42,3	0,0	30,8	42,3	61,5
49	46,2	57,7	0,0	61,5	53,8	50,0
50	46,2	15,4	0,0	34,6	26,9	34,6
Valor médio	43,6	40,6	0,0	40,2	41,7	40,1

Tabela C.1.4 Precisão da classificação binária descafeinado/café com PCA=80% usando os classificadores *Ensemble*.

Análise ao minuto	<i>Boosted Tress</i>	<i>Bagged Trees</i>	<i>Subspace Discriminant</i>	<i>Subspace KNN</i>	<i>Rusboosted Trees</i>
1	0,0	30,8	26,9	23,1	30,8
2	0,0	42,3	38,5	46,2	15,4
3	0,0	46,2	42,3	50,0	11,5
4	0,0	50,0	23,1	46,2	15,4
5	0,0	42,3	30,8	23,1	38,5
6	0,0	26,9	61,5	53,9	38,5
7	0,0	19,2	23,1	26,9	11,5
8	0,0	53,8	30,8	46,2	38,5

Continua na próxima página

9	0,0	38,5	42,3	38,5	30,8
10	0,0	26,9	26,9	38,5	26,9
11	0,0	50,0	34,6	46,2	34,6
12	0,0	53,8	26,9	38,5	15,4
13	0,0	65,4	73,1	65,4	15,4
14	0,0	53,8	30,8	30,8	26,9
15	0,0	46,2	34,6	50,0	30,8
16	0,0	53,8	53,8	38,5	26,9
17	0,0	38,5	57,7	53,8	38,5
18	0,0	50,0	38,5	30,8	26,9
19	0,0	57,7	30,8	34,6	38,5
20	0,0	57,7	30,8	73,1	15,4
21	0,0	26,9	38,5	53,8	23,1
22	0,0	50,0	50,0	53,8	15,4
23	0,0	42,3	53,8	38,5	30,8
24	0,0	61,5	38,5	34,6	30,8
25	0,0	53,8	38,5	38,5	26,9
26	0,0	42,3	50,0	42,3	30,8
27	0,0	19,2	15,4	30,8	19,2
28	0,0	50,0	30,8	38,5	42,3
29	0,0	46,2	42,3	57,7	19,2
30	0,0	46,2	46,2	38,5	19,2
31	0,0	42,3	57,7	34,6	15,4
32	0,0	57,7	38,5	38,5	26,9
33	0,0	57,7	26,9	38,5	30,8
34	0,0	42,3	42,3	38,5	23,1
35	0,0	46,2	23,1	30,8	23,1
36	0,0	46,2	65,4	42,3	23,1
37	0,0	23,1	46,2	38,5	23,1
38	0,0	23,1	38,5	38,5	38,5
39	0,0	53,8	50,0	42,3	19,2
40	0,0	42,3	34,6	26,9	19,2
41	0,0	26,9	30,8	42,3	23,1
42	0,0	34,6	61,5	42,3	19,2
43	0,0	42,3	46,2	61,5	30,8
44	0,0	53,8	34,6	42,3	11,5
45	0,0	23,1	53,8	30,8	11,5
46	0,0	53,8	61,5	46,2	34,6
47	0,0	53,8	30,8	53,8	26,9
48	0,0	53,8	50,0	61,5	26,9

Continua na próxima página

49	0,0	53,8	53,8	50,0	30,8
50	0,0	46,2	23,1	50,0	26,9
Valor médio	0,0	44,4	40,6	42,6	25,4

C.2 Classificação Binária OF_placebo/OF_cafeína

Tabela C.2.1 Precisão da classificação binária OF_placebo/OF_cafeína com PCA=80% usando os classificadores de árvore de decisão, análise discriminante, regressão logística e naïve bayes.

Análise ao minuto	<i>Fine Tree</i>	<i>Medium Tree</i>	<i>Coarse Tree</i>	<i>Lineaar Discriminant</i>	<i>Logist Regression</i>	<i>Naïve Bayes Gaussiane</i>
1	69,2	69,2	73,1	61,5	57,7	65,4
2	69,2	69,2	69,2	57,7	61,5	65,4
3	65,4	65,4	65,4	57,7	57,7	69,2
4	65,4	65,4	65,4	50,0	50,0	57,7
5	65,4	65,4	65,4	61,5	65,4	61,5
6	69,2	69,2	69,2	73,1	73,1	65,4
7	50,0	50,0	50,0	50,0	53,8	76,9
8	50,0	50,0	50,0	50,0	50,0	34,6
9	65,4	65,4	65,4	53,8	50,0	50,0
10	61,5	61,5	61,5	73,1	65,4	73,1
11	65,4	65,4	65,4	61,5	69,2	69,2
12	69,2	69,2	69,2	65,4	69,2	69,2
13	65,4	65,4	65,4	61,5	61,5	57,7
14	65,4	65,4	65,4	69,2	73,1	61,5
15	69,2	69,2	69,2	73,1	69,2	57,7
16	61,5	61,5	61,5	69,2	69,2	53,8
17	73,1	73,1	73,1	61,5	57,7	65,4
18	57,7	57,7	57,7	57,7	61,5	65,4
19	73,1	73,1	73,1	57,7	57,7	53,8
20	65,4	65,4	65,4	69,2	69,2	65,4
21	76,9	76,9	76,9	65,4	73,1	76,9
22	61,5	61,5	61,5	65,4	69,2	61,5
23	57,7	57,7	57,7	57,7	65,4	57,7
24	53,8	53,8	53,8	69,2	57,7	57,7
25	61,5	61,5	61,5	73,1	73,1	65,4
26	80,8	80,8	80,8	57,7	57,7	61,5

Continua na próxima página

27	61,5	61,5	61,5	50,0	50,0	46,2
28	61,5	61,5	61,5	61,5	61,5	69,2
29	57,7	57,7	57,7	76,9	84,6	61,5
30	69,2	69,2	69,2	57,7	57,7	57,7
31	53,8	53,8	53,9	46,2	46,2	65,4
32	76,9	76,9	76,9	65,4	61,5	61,5
33	76,9	76,9	76,9	65,4	61,5	57,7
34	76,9	76,9	76,9	65,4	65,4	61,5
35	53,8	53,8	53,8	69,2	73,1	73,1
36	69,2	69,2	69,2	76,9	73,1	73,1
37	69,2	69,2	69,2	53,8	61,5	53,8
38	69,2	69,2	69,2	69,2	73,1	57,7
39	53,8	53,8	53,8	53,8	57,7	73,1
40	73,1	73,1	73,1	57,7	61,5	65,4
41	61,5	61,5	61,5	76,9	73,1	76,9
42	73,1	73,1	73,1	65,4	61,5	65,4
43	69,2	69,2	69,2	65,4	65,4	53,8
44	76,9	76,9	76,9	76,9	69,2	80,8
45	69,2	69,2	69,2	53,8	57,7	61,5
46	57,7	57,7	61,5	65,4	73,1	61,5
47	76,9	76,9	76,9	65,4	76,9	73,1
48	69,2	69,2	69,2	65,4	73,1	65,4
49	80,8	80,8	80,8	61,5	69,2	76,9
50	69,2	69,2	69,2	61,5	76,9	73,1
Valor médio	66,3	66,3	66,5	63,0	64,5	63,7

Tabela C.2.2 Precisão da classificação binária OF_placebo/OF_cafeína com PCA=80% usando os classificadores SVM.

Análise ao minuto	Linear SVM	Quadratic SVM	Cubic SVM	Fine Gaussian SVM	Medium Gaussian SVM	Coarse Gaussian SVM
1	69,2	65,4	65,4	73,1	0,0	0,0
2	69,2	57,7	61,5	65,4	0,0	0,0
3	65,4	53,8	46,2	65,4	0,0	0,0
4	61,5	69,2	69,2	65,4	0,0	0,0
5	61,5	69,2	69,2	65,4	0,0	0,0
6	65,4	80,8	80,8	69,2	0,0	0,0
7	65,4	61,5	65,4	57,7	0,0	0,0
8	57,7	61,5	69,2	69,2	0,0	0,0

Continua na próxima página

9	53,8	46,2	53,8	53,8	0,0	0,0
10	65,4	61,5	57,7	73,1	0,0	0,0
11	57,7	50,0	61,5	69,2	0,0	0,0
12	69,2	84,6	84,6	73,1	0,0	0,0
13	73,1	50,0	50,0	65,4	0,0	0,0
14	65,4	76,9	69,2	69,2	0,0	0,0
15	69,2	57,7	61,5	69,2	0,0	0,0
16	73,1	65,4	69,2	73,1	0,0	0,0
17	57,7	53,8	57,7	61,5	0,0	0,0
18	57,7	50,0	57,7	57,7	0,0	0,0
19	73,1	73,1	65,4	73,1	0,0	0,0
20	69,2	69,2	73,1	69,2	0,0	0,0
21	61,5	84,6	76,9	73,1	0,0	0,0
22	65,4	65,4	65,4	65,4	0,0	0,0
23	57,7	57,7	53,8	53,8	0,0	0,0
24	61,5	53,8	50,0	57,7	0,0	0,0
25	69,2	69,2	61,5	65,4	0,0	0,0
26	61,5	57,7	65,4	69,2	0,0	0,0
27	50,0	53,8	53,8	69,2	0,0	0,0
28	53,8	53,8	50,0	61,5	0,0	0,0
29	69,2	69,2	73,1	76,9	0,0	0,0
30	61,5	57,7	73,1	65,4	0,0	0,0
31	65,4	53,8	61,5	65,4	0,0	0,0
32	73,1	57,7	57,7	76,9	0,0	0,0
33	69,2	69,2	69,2	76,9	0,0	0,0
34	69,2	65,4	61,5	73,1	0,0	0,0
35	73,1	69,2	61,5	73,1	0,0	0,0
36	65,4	76,9	84,6	76,9	0,0	0,0
37	46,2	50,0	46,2	57,7	0,0	0,0
38	65,4	50,0	61,5	53,9	0,0	0,0
39	57,7	61,5	61,5	65,4	0,0	0,0
40	61,5	53,8	57,7	61,5	0,0	0,0
41	73,1	76,9	73,1	76,9	0,0	0,0
42	61,5	69,2	73,1	69,2	0,0	0,0
43	65,4	61,5	61,5	69,2	0,0	0,0
44	69,2	73,1	73,1	70,8	0,0	0,0
45	46,2	65,4	42,3	69,2	0,0	0,0
46	73,1	69,2	57,7	57,7	0,0	0,0
47	61,5	80,8	73,1	73,1	0,0	0,0
48	57,7	50,0	61,5	69,2	0,0	0,0

Continua na próxima página

49	69,2	69,2	61,5	69,2	0,0	0,0
50	53,8	57,7	76,9	61,5	0,0	0,0
Valor médio	63,8	63,2	63,8	67,3	0,0	0,0

Tabela C.2.3 Precisão da classificação binária OF_placebo/OF_cafeína com PCA=80% usando os classificadores KNN.

Análise ao minuto	<i>Fine KNN</i>	<i>Medium KNN</i>	<i>Coarse KNN</i>	<i>Cosine KNN</i>	<i>Cubic KNN</i>	<i>Weighted KNN</i>
1	61,5	46,2	0,0	73,1	50,0	53,8
2	61,5	50,0	0,0	65,4	42,3	50,0
3	53,8	53,8	0,0	65,4	46,2	30,8
4	73,1	46,2	0,0	61,5	61,5	61,5
5	65,4	65,4	0,0	73,1	73,1	73,1
6	69,2	42,3	0,0	65,4	50,0	65,4
7	50,0	57,7	0,0	57,7	50,0	53,8
8	65,4	50,0	0,0	65,4	50,0	46,2
9	61,5	53,8	0,0	53,8	42,3	42,3
10	46,2	57,7	0,0	73,1	57,7	57,7
11	61,5	50,0	0,0	61,5	50,0	46,2
12	80,8	65,4	0,0	73,1	61,5	80,8
13	57,7	46,2	0,0	61,5	46,2	46,2
14	53,8	57,7	0,0	60,8	57,7	53,8
15	61,5	53,8	0,0	65,4	46,2	50,0
16	73,1	46,2	0,0	65,4	53,8	57,7
17	76,9	61,5	0,0	73,1	61,5	61,5
18	57,7	38,5	0,0	69,2	46,2	57,7
19	69,2	50,0	0,0	69,2	50,0	61,5
20	69,2	57,7	0,0	61,5	61,5	61,5
21	73,1	46,2	0,0	61,5	46,2	61,5
22	57,7	65,4	0,0	65,4	53,8	65,4
23	61,5	42,3	0,0	69,2	42,3	50,0
24	65,4	53,8	0,0	65,4	57,7	65,4
25	61,5	46,2	0,0	76,9	53,9	46,2
26	57,7	53,8	0,0	57,7	57,7	65,4
27	61,5	50,0	0,0	65,4	46,2	38,5
28	57,7	50,0	0,0	69,2	57,7	46,2
29	69,2	57,7	0,0	69,2	69,2	65,4
30	61,5	46,2	0,0	61,5	42,3	50,0

Continua na próxima página

31	69,2	42,3	0,0	65,4	42,3	50,0
32	65,4	50,0	0,0	76,9	46,2	61,5
33	65,4	57,7	0,0	76,9	61,5	57,7
34	61,5	50,0	0,0	65,4	46,2	53,8
35	69,2	46,2	0,0	73,1	53,8	57,7
36	73,1	50,0	0,0	61,5	57,7	57,7
37	53,8	53,8	0,0	57,7	50,0	30,8
38	61,5	57,7	0,0	73,1	50,0	65,4
39	69,2	53,8	0,0	53,8	50,0	50,0
40	65,4	50,0	0,0	57,7	50,0	53,8
41	61,5	53,8	0,0	73,1	50,0	65,4
42	69,2	57,7	0,0	73,1	61,5	61,5
43	53,8	42,3	0,0	69,2	42,3	50,0
44	76,9	57,7	0,0	76,9	53,8	65,4
45	46,2	42,3	0,0	61,5	42,3	42,3
46	57,7	50,0	0,0	73,1	46,2	50,0
47	76,9	57,7	0,0	57,7	50,0	65,4
48	61,5	53,8	0,0	57,7	53,8	57,7
49	73,1	61,5	0,0	61,5	57,7	61,5
50	73,1	46,2	0,0	61,5	46,2	57,7
Valor médio	64,0	51,9	0,0	66,1	51,9	55,6

Tabela C.2.4 Precisão da classificação binária OF_placebo/OF_cafeína com PCA=80% usando os classificadores *Ensemble*.

Análise ao minuto	<i>Boosted Tress</i>	<i>Bagged Trees</i>	<i>Subspace Discriminant</i>	<i>Subspace KNN</i>	<i>Rusboosted Trees</i>
1	0,0	65,4	61,5	61,5	15,4
2	0,0	53,8	57,7	61,5	46,2
3	0,0	61,5	53,8	42,3	26,9
4	0,0	57,7	50,0	73,1	7,7
5	0,0	61,5	61,5	69,2	19,2
6	0,0	69,2	73,1	65,4	38,5
7	0,0	57,7	50,0	57,7	19,2
8	0,0	57,7	50,0	53,8	15,4
9	0,0	61,5	50,0	73,1	30,8
10	0,0	57,7	73,1	50,0	23,1
11	0,0	65,4	61,5	50,0	15,4
12	0,0	65,4	65,4	76,9	15,4

Continua na próxima página

13	0,0	73,1	61,5	57,7	23,1
14	0,0	80,8	69,2	57,7	11,5
15	0,0	53,8	73,1	61,5	22,1
16	0,0	61,5	69,2	61,5	23,1
17	0,0	69,2	61,5	69,2	23,1
18	0,0	57,7	57,7	57,7	23,1
19	0,0	65,4	57,7	65,4	38,5
20	0,0	69,2	69,2	76,9	42,3
21	0,0	80,8	65,4	80,8	26,9
22	0,0	65,4	65,4	57,7	26,9
23	0,0	61,5	57,7	53,8	23,1
24	0,0	61,5	61,5	57,7	7,7
25	0,0	73,1	73,1	73,1	46,2
26	0,0	57,7	57,7	61,5	23,1
27	0,0	73,1	50,0	46,2	23,1
28	0,0	65,4	61,5	57,7	15,4
29	0,0	53,8	76,9	69,2	30,8
30	0,0	65,4	57,7	73,1	11,5
31	0,0	53,8	46,2	69,2	26,9
32	0,0	61,5	61,5	53,8	34,6
33	0,0	42,3	61,5	57,7	11,5
34	0,0	69,2	65,4	61,5	11,5
35	0,0	73,1	69,2	73,1	15,4
36	0,0	61,5	80,8	69,2	26,9
37	0,0	61,5	53,8	52,8	26,9
38	0,0	61,5	69,2	61,5	34,6
39	0,0	76,9	53,8	53,8	30,8
40	0,0	69,2	57,7	73,1	38,5
41	0,0	76,9	76,9	57,7	23,1
42	0,0	61,5	61,5	73,1	26,9
43	0,0	69,2	65,4	53,8	38,5
44	0,0	69,2	76,9	65,4	26,9
45	0,0	57,7	53,8	42,3	23,1
46	0,0	53,8	65,4	69,2	26,9
47	0,0	76,9	65,4	73,1	11,5
48	0,0	73,1	65,4	69,2	19,2
49	0,0	73,1	61,5	69,2	19,2
50	0,0	61,5	65,4	84,6	23,1
Valor médio	0,0	64,5	62,6	63,1	24,2

Precisão dos Classificadores com PCA=70%

D.1 Classificação Binária Descafeinado/Café

Tabela D.1.1 Precisão da classificação binária descafeinado/café com PCA=70% usando os classificadores de árvore de decisão, análise discriminante, regressão logística e *naïve bayes*.

Análise ao minuto	<i>Fine Tree</i>	<i>Medium Tree</i>	<i>Coarse Tree</i>	<i>Lineaar Discriminant</i>	<i>Logist Regression</i>	<i>Naïve Bayes Gaussiane</i>
1	38,5	38,5	38,5	30,8	30,8	34,6
2	26,9	26,9	26,9	46,2	46,2	38,5
3	42,3	42,3	42,3	50,0	50,0	34,6
4	46,2	46,2	50,0	26,9	26,9	34,6
5	26,9	26,9	30,8	26,9	30,8	23,1
6	53,8	53,8	53,8	57,7	57,7	50,0
7	34,6	34,6	34,6	15,4	15,4	38,5
8	46,2	46,2	46,2	30,8	30,8	26,9
9	46,2	46,2	46,2	42,3	42,3	26,9
10	53,8	53,8	53,8	38,5	38,5	19,2
11	46,2	46,2	46,2	38,5	38,5	38,5
12	42,3	42,3	38,5	19,2	19,2	50,0
13	61,5	61,5	61,5	73,1	73,1	73,1
14	53,8	53,8	53,8	34,6	34,6	30,8
15	69,2	69,2	69,2	38,5	46,2	46,2
16	46,2	46,2	46,2	42,3	42,3	42,3
17	53,8	53,8	57,7	46,2	50,0	53,8
18	34,6	34,6	34,6	15,4	19,2	26,9
19	42,3	42,3	42,3	23,1	23,1	15,4
20	46,2	46,3	46,2	15,4	15,4	26,9
21	50,0	50,0	50,0	42,3	42,3	53,8
22	42,3	42,3	42,3	46,2	46,2	46,2

Continua na próxima página

23	61,5	61,5	61,5	61,5	53,8	65,4
24	50,0	50,0	50,0	38,5	38,5	57,7
25	50,0	50,0	50,0	38,5	38,5	42,3
26	57,7	57,7	57,7	42,3	42,3	42,3
27	26,9	26,9	30,8	15,4	15,4	30,8
28	50,0	50,0	50,0	34,6	34,6	42,3
29	38,5	38,5	38,5	57,7	65,4	53,9
30	34,6	34,6	34,6	26,9	26,9	38,5
31	53,8	53,8	53,8	34,6	34,6	42,3
32	50,0	50,0	50,0	38,5	38,5	61,5
33	57,7	57,7	57,7	23,1	23,1	50,0
34	23,1	23,1	23,1	30,8	30,8	34,6
35	30,8	30,8	30,8	30,8	42,3	38,5
36	69,2	69,2	69,2	73,1	76,9	65,4
37	38,5	38,5	38,5	46,2	53,8	42,3
38	50,0	50,0	50,0	42,3	42,3	42,3
39	30,8	30,8	30,8	30,8	30,8	26,9
40	15,4	15,4	15,4	19,2	19,2	26,9
41	42,3	42,3	42,3	34,6	34,6	34,6
42	50,0	50,0	53,8	69,2	69,2	57,7
43	73,1	73,1	73,1	50,0	53,8	65,4
44	46,2	46,2	46,2	34,6	30,8	46,2
45	50,0	50,0	50,0	53,8	53,8	42,3
46	53,8	53,8	53,8	57,7	57,7	57,7
47	38,5	38,5	38,5	30,8	30,8	30,8
48	69,2	69,2	69,2	46,2	50,0	34,6
49	53,8	53,8	53,8	57,7	53,8	57,7
50	53,8	53,8	53,8	19,2	19,2	30,8
Valor médio	46,5	46,5	46,8	38,8	39,6	41,9

Tabela D.1.2 Precisão da classificação binária descafeinado/café com PCA=70% usando os classificadores SVM.

Análise ao minuto	<i>Linear SVM</i>	<i>Quadratic SVM</i>	<i>Cubic SVM</i>	<i>Fine Gaussian SVM</i>	<i>Medium Gaussian SVM</i>	<i>Coarse Gaussian SVM</i>
1	34,6	30,8	34,6	7,7	0,0	0,0
2	38,5	46,2	30,8	23,1	0,0	0,0
3	38,5	46,2	34,6	34,6	0,0	0,0
4	19,2	30,8	38,5	3,8	0,0	0,0

Continua na próxima página

5	19,2	23,1	26,9	3,8	0,0	0,0
6	69,2	53,8	42,3	61,5	0,0	0,0
7	23,1	46,2	42,3	23,1	0,0	0,0
8	26,9	42,3	34,6	30,8	0,0	0,0
9	42,3	38,5	34,6	42,3	0,0	0,0
10	23,1	42,3	38,5	0,0	0,0	0,0
11	50,0	38,5	38,5	0,0	0,0	53,8
12	38,5	34,6	38,5	19,2	0,0	0,0
13	69,2	76,9	65,4	73,1	0,0	0,0
14	26,9	34,6	30,8	26,9	0,0	0,0
15	34,6	57,7	53,8	34,6	0,0	0,0
16	46,2	46,2	34,6	30,8	0,0	0,0
17	53,8	46,2	34,6	46,2	0,0	0,0
18	19,2	19,2	26,9	15,4	0,0	0,0
19	11,5	34,6	42,3	7,7	0,0	0,0
20	15,4	23,1	42,3	19,2	0,0	0,0
21	38,5	50,0	46,2	53,8	0,0	0,0
22	30,8	42,3	46,2	34,6	0,0	0,0
23	57,7	53,8	38,5	46,2	0,0	0,0
24	42,3	46,2	53,8	46,2	0,0	0,0
25	38,5	38,5	38,5	42,3	0,0	0,0
26	42,3	30,8	38,5	42,3	0,0	0,0
27	19,2	23,1	23,1	11,5	0,0	0,0
28	30,8	46,2	50,0	26,9	0,0	0,0
29	57,7	61,5	50,0	69,2	0,0	0,0
30	38,5	46,2	42,3	38,5	0,0	0,0
31	38,5	36,2	53,8	42,3	0,0	0,0
32	42,3	65,4	61,5	42,3	0,0	0,0
33	23,1	34,6	46,2	23,1	0,0	0,0
34	26,9	30,8	34,6	23,1	0,0	0,0
35	23,1	42,3	46,2	23,1	0,0	0,0
36	69,2	57,7	50,0	53,8	0,0	0,0
37	38,5	42,3	42,3	46,2	0,0	0,0
38	34,6	46,2	30,8	26,9	0,0	0,0
39	26,9	38,5	46,2	26,9	0,0	0,0
40	19,2	19,2	39,8	3,8	0,0	0,0
41	46,2	38,5	46,2	38,5	0,0	0,0
42	73,1	50,0	34,6	53,8	0,0	0,0
43	46,2	34,6	42,3	30,8	0,0	0,0
44	34,6	34,6	26,9	26,9	0,0	0,0

Continua na próxima página

45	46,2	53,8	61,5	50,0	0,0	0,0
46	53,8	61,5	53,8	53,8	0,0	0,0
47	23,1	42,3	46,2	26,9	0,0	0,0
48	38,5	34,6	34,6	34,6	0,0	0,0
49	57,7	65,4	65,4	65,4	0,0	0,0
50	15,4	38,5	42,3	7,7	0,0	0,0
Valor médio	37,5	42,3	42,0	32,3	0,0	1,1

Tabela D.1.3 Precisão da classificação binária descafeinado/café com PCA=70% usando os classificadores KNN.

Análise ao minuto	<i>Fine KNN</i>	<i>Medium KNN</i>	<i>Coarse KNN</i>	<i>Cosine KNN</i>	<i>Cubic KNN</i>	<i>Weighted KNN</i>
1	30,8	26,9	0,0	38,5	30,8	19,2
2	30,8	50,0	0,0	53,8	42,3	30,8
3	46,2	42,3	0,0	38,5	38,5	42,3
4	42,3	26,9	0,0	23,1	26,9	23,1
5	15,4	30,8	0,0	26,9	34,6	15,4
6	53,8	46,2	0,0	50,0	50,0	57,7
7	30,8	38,5	0,0	26,9	38,5	38,5
8	30,8	38,5	0,0	34,6	38,5	30,8
9	34,6	30,8	0,0	30,8	42,3	42,3
10	38,5	38,5	0,0	26,9	38,5	15,4
11	53,8	42,3	0,0	42,3	34,6	42,3
12	42,3	38,5	0,0	38,5	30,8	30,8
13	50,0	65,4	0,0	61,5	50,0	65,4
14	46,2	26,9	0,0	38,5	23,1	26,9
15	69,2	38,5	0,0	46,2	38,5	53,8
16	30,8	30,8	0,0	30,8	26,9	34,6
17	61,5	46,2	0,0	42,3	46,2	46,2
18	30,8	30,8	0,0	23,1	23,1	23,1
19	19,2	38,5	0,0	34,6	38,5	23,1
20	50,0	34,6	0,0	15,4	42,3	26,9
21	42,3	53,8	0,0	46,2	57,7	42,3
22	53,8	26,9	0,0	38,5	23,1	38,5
23	42,3	50,0	0,0	53,8	46,2	42,3
24	38,5	34,6	0,0	46,2	30,8	42,3
25	34,6	50,0	0,0	46,2	53,8	30,8
26	38,5	46,2	0,0	42,3	50,0	50,0

Continua na próxima página

27	23,1	34,6	0,0	38,5	34,6	15,4
28	38,5	46,2	0,0	19,2	46,2	50,0
29	65,4	38,5	0,0	57,7	42,3	61,5
30	23,1	46,2	0,0	26,9	53,8	46,2
31	38,5	38,5	0,0	26,9	34,6	50,0
32	53,8	38,5	0,0	57,7	46,2	42,3
33	38,5	34,6	0,0	26,9	38,5	26,9
34	23,1	30,8	0,0	30,8	38,5	23,1
35	53,8	34,6	0,0	26,9	42,3	42,3
36	50,0	53,8	0,0	57,7	50,0	53,8
37	34,6	46,2	0,0	42,3	38,5	46,2
38	38,5	46,2	0,0	46,2	50,0	42,3
39	46,2	34,6	0,0	34,6	15,4	30,8
40	26,9	34,6	0,0	30,8	34,6	23,1
41	50,0	34,6	0,0	42,3	38,5	42,3
42	50,0	50,0	0,0	61,5	50,0	53,8
43	50,0	50,0	0,0	57,7	57,7	50,0
44	42,3	46,2	0,0	38,5	50,0	38,5
45	42,3	53,8	0,0	53,8	42,3	50,0
46	50,0	57,7	0,0	57,7	57,7	46,2
47	42,3	23,1	0,0	30,8	30,8	30,8
48	69,2	42,3	0,0	30,8	46,2	42,3
49	46,2	53,8	0,0	46,2	53,8	50,0
50	30,8	19,2	0,0	15,4	11,5	30,8
Valor médio	41,7	40,2	0,0	39,1	40,0	38,5

Tabela D.1.4 Precisão da classificação binária descafeinado/café com PCA=70% usando os classificadores *Ensemble*.

Análise ao minuto	<i>Boosted Tress</i>	<i>Bagged Trees</i>	<i>Subspace Discriminant</i>	<i>Subspace KNN</i>	<i>Rusboosted Trees</i>
1	0,0	42,3	30,8	19,2	30,8
2	0,0	38,5	46,2	30,8	26,9
3	0,0	34,6	46,2	34,6	23,1
4	0,0	26,9	26,9	38,5	23,1
5	0,0	23,1	23,1	26,9	26,9
6	0,0	38,5	61,5	65,4	30,8
7	0,0	42,3	15,4	34,6	34,6
8	0,0	23,1	30,8	30,8	23,1

Continua na próxima página

9	0,0	61,5	42,3	42,3	42,3
10	0,0	30,8	34,6	30,8	38,5
11	0,0	42,3	38,5	50,0	26,9
12	0,0	34,6	19,2	30,8	30,8
13	0,0	76,9	73,1	69,2	23,1
14	0,0	38,5	34,6	38,5	26,9
15	0,0	57,7	38,5	50,0	23,1
16	0,0	50,0	42,3	30,8	23,1
17	0,0	46,2	50,0	61,5	19,2
18	0,0	34,6	15,4	23,1	19,2
19	0,0	34,6	23,1	26,9	38,5
20	0,0	34,6	15,4	65,4	19,2
21	0,0	50,0	42,3	57,7	26,9
22	0,0	34,6	46,2	50,0	19,2
23	0,0	38,5	61,5	34,6	15,4
24	0,0	53,8	34,6	30,8	7,7
25	0,0	42,3	42,3	30,8	26,9
26	0,0	42,3	42,3	42,3	34,6
27	0,0	19,2	15,4	34,6	19,2
28	0,0	61,5	34,6	50,0	30,8
29	0,0	53,8	57,7	61,5	19,2
30	0,0	38,5	26,9	26,9	26,9
31	0,0	26,9	34,6	38,5	34,6
32	0,0	50,0	38,5	50,0	26,9
33	0,0	38,5	23,1	34,6	23,1
34	0,0	30,8	30,8	26,9	23,1
35	0,0	38,5	30,8	42,3	11,5
36	0,0	61,5	73,1	53,8	23,1
37	0,0	46,2	46,2	42,3	34,6
38	0,0	53,8	42,3	46,2	46,2
39	0,0	38,5	30,8	46,2	26,9
40	0,0	30,8	19,2	26,9	15,4
41	0,0	50,0	34,6	50,0	19,2
42	0,0	65,4	69,2	53,8	26,9
43	0,0	53,8	50,0	50,0	19,2
44	0,0	42,3	34,6	53,8	11,5
45	0,0	46,2	54,8	30,8	34,6
46	0,0	61,5	57,7	50,0	23,1
47	0,0	46,2	30,8	50,0	15,4
48	0,0	53,8	46,2	73,1	30,8

Continua na próxima página

49	0,0	46,2	57,7	50,0	34,6
50	0,0	30,8	15,4	53,8	23,1
Valor médio	0,0	43,2	38,6	42,5	25,6

D.2 Classificação Binária OF_placebo/OF_cafeína

Tabela D.2.1 Precisão da classificação binária OF_placebo/OF_cafeína com PCA=70% usando os classificadores de árvore de decisão, análise discriminante, regressão logística e naïve bayes.

Análise ao minuto	<i>Fine Tree</i>	<i>Medium Tree</i>	<i>Coarse Tree</i>	<i>Lineaar Discriminant</i>	<i>Logist Regression</i>	<i>Naïve Bayes Gaussiane</i>
1	73,1	73,1	73,1	69,2	65,4	65,4
2	65,4	65,4	65,4	57,7	61,5	57,7
3	76,9	76,9	76,9	57,7	57,7	50,0
4	65,4	65,4	65,4	46,2	46,2	57,7
5	65,4	65,4	65,4	65,4	65,4	65,4
6	61,5	61,5	61,5	69,2	69,2	69,2
7	53,8	53,8	53,8	53,8	53,8	61,5
8	50,0	50,0	50,0	53,8	53,8	38,5
9	69,2	69,2	69,2	57,7	57,7	38,5
10	61,5	61,5	61,5	76,9	69,2	73,1
11	53,8	53,8	53,8	69,2	69,2	65,4
12	73,1	73,1	73,1	73,1	73,1	65,4
13	69,2	69,2	69,2	61,5	61,5	61,5
14	65,4	65,4	65,4	61,5	61,5	50,0
15	65,4	65,4	65,4	69,2	69,2	61,5
16	69,2	69,2	69,2	69,2	73,1	57,7
17	69,2	69,2	69,2	69,2	69,2	65,4
18	53,8	53,8	53,8	57,7	53,8	57,7
19	65,4	65,4	65,4	65,4	61,5	53,8
20	61,5	61,5	61,5	69,2	69,2	69,2
21	53,8	53,8	53,8	57,7	57,7	69,2
22	65,4	65,4	65,4	65,4	57,7	61,5
23	61,5	61,5	61,5	57,7	61,5	61,5
24	61,5	61,5	61,5	57,7	57,7	42,3
25	65,4	65,4	65,4	69,2	76,9	57,7
26	80,8	80,8	80,8	57,7	61,5	53,8

Continua na próxima página

27	57,7	57,7	57,7	53,8	53,8	53,8
28	65,4	65,4	65,4	53,8	57,7	69,2
29	61,5	61,5	61,5	76,9	80,8	69,2
30	69,2	69,2	69,2	57,7	57,7	65,4
31	65,4	65,4	65,4	61,5	61,5	65,4
32	76,9	76,9	76,9	69,2	61,5	69,2
33	65,4	65,4	65,4	65,4	65,4	50,0
34	76,9	76,9	76,9	69,2	65,4	53,8
35	57,7	57,7	57,7	69,2	69,2	57,7
36	65,4	65,4	65,4	73,1	73,1	69,2
37	69,2	69,2	69,2	50,0	53,8	53,8
38	73,1	73,1	73,1	69,2	73,1	65,4
39	42,3	42,3	42,3	53,8	53,8	53,8
40	69,2	69,2	69,2	61,5	61,5	65,4
41	65,4	65,4	65,4	76,9	69,2	65,4
42	73,1	73,1	73,1	61,5	65,4	61,5
43	73,1	73,1	73,1	65,4	65,4	57,7
44	73,1	73,1	73,1	69,2	65,4	65,4
45	61,5	61,5	61,5	57,7	61,5	57,7
46	57,7	57,7	57,7	73,1	73,1	69,2
47	76,9	76,9	76,9	69,2	73,1	73,1
48	69,2	69,2	69,2	69,2	65,4	65,4
49	84,6	84,6	84,6	65,4	69,2	65,4
50	73,1	73,1	73,1	57,7	57,7	69,2
Valor médio	66,0	66,0	66,0	63,8	63,8	60,8

Tabela D.2.2 Precisão da classificação binária OF_placebo/OF_cafeína com PCA=70% usando os classificadores SVM.

Análise ao minuto	<i>Linear SVM</i>	<i>Quadratic SVM</i>	<i>Cubic SVM</i>	<i>Fine Gaussian SVM</i>	<i>Medium Gaussian SVM</i>	<i>Coarse Gaussian SVM</i>
1	69,2	50,0	57,7	73,1	0,0	0,0
2	69,2	73,1	57,7	76,9	0,0	0,0
3	61,5	53,8	50,0	73,1	0,0	0,0
4	57,7	69,2	61,5	53,8	0,0	0,0
5	65,4	61,5	65,4	73,1	0,0	0,0
6	80,8	61,5	61,5	65,4	0,0	0,0
7	53,8	65,4	53,8	61,5	0,0	0,0
8	65,4	65,4	69,2	73,1	0,0	0,0

Continua na próxima página

9	65,4	53,8	69,2	69,2	0,0	0,0
10	73,1	61,5	53,8	73,1	0,0	0,0
11	76,9	46,2	38,5	69,2	0,0	0,0
12	69,2	80,8	80,8	73,1	0,0	0,0
13	61,5	46,2	50,0	50,0	0,0	0,0
14	53,8	61,5	69,2	57,7	0,0	0,0
15	61,5	57,7	69,2	61,5	0,0	0,0
16	69,2	73,1	80,8	69,2	0,0	0,0
17	61,5	57,7	69,2	57,7	0,0	0,0
18	61,5	65,4	76,9	69,2	0,0	0,0
19	73,1	73,1	61,5	73,1	0,0	0,0
20	76,9	73,1	61,5	73,1	0,0	0,0
21	50,0	61,5	65,4	53,8	0,0	0,0
22	65,4	57,7	61,5	65,4	0,0	0,0
23	57,7	50,0	46,2	65,4	0,0	0,0
24	65,4	61,5	65,4	61,5	0,0	0,0
25	73,1	69,2	69,2	61,5	0,0	0,0
26	65,4	65,4	76,9	73,1	0,0	0,0
27	53,8	42,3	57,7	73,1	0,0	0,0
28	57,7	57,7	50,0	57,7	0,0	0,0
29	69,2	73,1	65,4	76,9	0,0	0,0
30	61,5	57,7	69,2	69,2	0,0	0,0
31	61,5	61,5	69,2	73,1	0,0	0,0
32	69,2	61,5	57,7	76,9	0,0	0,0
33	76,9	69,2	53,8	76,9	0,0	0,0
34	76,9	69,2	61,5	76,9	0,0	0,0
35	73,1	61,5	61,5	73,1	0,0	0,0
36	76,9	76,9	76,9	80,8	0,0	0,0
37	50,0	57,7	65,4	61,5	0,0	0,0
38	69,2	53,8	53,8	65,4	0,0	0,0
39	53,8	53,8	53,8	61,5	0,0	0,0
40	65,4	61,5	69,2	65,4	0,0	0,0
41	76,9	73,1	65,4	69,2	0,0	0,0
42	69,2	61,5	57,7	69,2	0,0	0,0
43	53,8	57,7	53,8	61,5	0,0	0,0
44	65,4	73,1	65,4	73,1	0,0	0,0
45	57,7	65,4	50,0	61,5	0,0	0,0
46	73,1	76,9	65,4	61,5	0,0	0,0
47	69,2	69,2	65,4	61,5	0,0	0,0
48	69,2	57,7	61,5	69,2	0,0	0,0

Continua na próxima página

49	69,2	69,2	69,2	73,1	0,0	0,0
50	53,8	65,4	73,1	61,5	0,0	0,0
Valor médio	65,5	62,8	62,7	67,5	0,0	0,0

Tabela D.2.3 Precisão da classificação binária OF_placebo/OF_cafeína com PCA=70% usando os classificadores KNN.

Análise ao minuto	<i>Fine KNN</i>	<i>Medium KNN</i>	<i>Coarse KNN</i>	<i>Cosine KNN</i>	<i>Cubic KNN</i>	<i>Weighted KNN</i>
1	61,5	53,8	0,0	69,2	53,8	65,4
2	61,5	65,4	0,0	73,1	61,5	65,4
3	57,7	46,2	0,0	65,4	42,3	42,3
4	80,8	50,0	0,0	65,4	50,0	69,2
5	61,5	76,9	0,0	69,2	76,9	61,5
6	65,4	53,8	0,0	65,4	53,8	73,1
7	61,5	50,0	0,0	61,5	61,5	57,7
8	65,4	61,5	0,0	65,4	57,7	61,5
9	69,2	53,8	0,0	65,4	53,8	65,4
10	46,2	65,4	0,0	69,2	57,7	57,7
11	53,8	46,2	0,0	57,7	46,2	50,0
12	76,9	80,8	0,0	76,9	80,8	73,1
13	50,0	46,2	0,0	57,7	46,2	50,0
14	61,5	57,7	0,0	73,1	61,5	57,7
15	61,5	53,8	0,0	65,4	53,8	57,7
16	69,2	61,5	0,0	57,7	65,4	61,5
17	69,2	61,5	0,0	61,5	61,5	69,2
18	69,2	57,7	0,0	65,4	65,4	73,1
19	42,3	65,4	0,0	76,9	61,5	61,5
20	46,2	69,2	0,0	65,4	61,5	65,4
21	65,4	38,5	0,0	50,0	38,5	65,4
22	53,8	69,2	0,0	69,2	76,9	65,4
23	42,3	46,2	0,0	69,2	42,3	46,2
24	65,4	69,2	0,0	69,2	73,1	69,2
25	65,4	50,0	0,0	76,9	50,0	61,5
26	65,4	65,4	0,0	69,2	69,2	69,2
27	50,0	50,0	0,0	57,7	50,0	50,0
28	53,8	61,5	0,0	65,4	53,8	53,8
29	69,2	69,2	0,0	69,2	69,2	76,9
30	76,9	42,3	0,0	61,5	50,0	57,7

Continua na próxima página

31	73,1	53,8	0,0	69,2	46,2	57,7
32	65,4	57,7	0,0	76,9	69,2	53,8
33	53,8	65,4	0,0	76,9	61,5	65,4
34	61,5	57,7	0,0	65,4	50,0	53,8
35	65,4	65,4	0,0	80,8	53,8	69,2
36	65,4	80,8	0,0	65,4	73,1	76,9
37	73,1	46,2	0,0	67,7	53,8	53,8
38	57,7	65,4	0,0	69,2	65,4	61,5
39	57,7	50,0	0,0	53,8	57,7	61,5
40	76,9	57,7	0,0	57,7	61,5	69,2
41	53,8	46,2	0,0	76,9	53,8	57,7
42	65,4	57,7	0,0	65,4	53,8	65,4
43	50,0	53,8	0,0	65,4	65,4	57,7
44	65,4	57,7	0,0	69,2	61,5	69,2
45	65,4	42,3	0,0	57,7	38,5	61,5
46	61,5	53,8	0,0	69,2	53,8	53,8
47	76,9	73,1	0,0	61,5	73,1	65,4
48	53,8	42,3	0,0	65,4	46,2	42,3
49	73,1	50,0	0,0	61,5	57,7	65,4
50	61,5	53,8	0,0	69,2	53,8	69,2
Valor médio	62,3	57,4	0,0	66,6	57,9	61,7

Tabela D.2.4 Precisão da classificação binária OF_placebo/OF_cafeína com PCA=70% usando os classificadores *Ensemble*.

Análise ao minuto	<i>Boosted Tress</i>	<i>Bagged Trees</i>	<i>Subspace Discriminant</i>	<i>Subspace KNN</i>	<i>Rusboosted Trees</i>
1	0,0	65,4	65,4	65,4	15,4
2	0,0	50,0	61,5	65,4	26,9
3	0,0	80,8	57,7	46,2	34,6
4	0,0	73,1	46,2	61,5	34,6
5	0,0	61,5	61,5	73,1	23,1
6	0,0	61,5	73,1	73,1	23,1
7	0,0	65,4	50,0	61,5	23,6
8	0,0	46,2	53,8	61,5	26,9
9	0,0	65,4	57,7	73,1	30,8
10	0,0	57,7	73,1	50,0	23,1
11	0,0	65,4	69,2	53,8	7,7
12	0,0	69,2	73,1	73,1	11,5

Continua na próxima página

13	0,0	53,8	61,5	53,8	15,4
14	0,0	69,2	61,5	61,5	30,8
15	0,0	53,8	69,2	61,5	34,6
16	0,0	73,1	69,2	73,1	15,4
17	0,0	61,5	61,5	61,5	26,9
18	0,0	53,8	61,5	61,5	15,5
19	0,0	57,7	61,5	57,7	38,5
20	0,0	76,9	69,2	53,8	26,9
21	0,0	69,2	57,7	69,2	23,1
22	0,0	73,1	65,4	57,7	11,5
23	0,0	69,2	57,7	46,2	30,8
24	0,0	57,7	57,7	57,7	19,2
25	0,0	57,7	69,2	73,1	26,9
26	0,0	73,1	61,5	57,7	26,9
27	0,0	65,4	53,8	46,2	26,9
28	0,0	69,2	57,7	50,0	15,4
29	0,0	57,7	76,9	65,4	11,5
30	0,0	69,2	57,7	69,2	19,2
31	0,0	69,2	61,5	73,1	11,5
32	0,0	65,4	69,2	61,5	15,4
33	0,0	57,7	65,4	53,8	19,2
34	0,0	76,9	69,2	57,7	30,8
35	0,0	65,4	69,2	73,1	19,2
36	0,0	69,2	76,9	69,2	26,9
37	0,0	57,7	50,0	69,2	15,4
38	0,0	76,9	69,2	65,4	26,9
39	0,0	57,7	53,8	65,4	11,5
40	0,0	61,5	61,5	76,9	30,8
41	0,0	69,2	76,9	46,2	19,2
42	0,0	65,4	61,5	65,4	19,2
43	0,0	57,7	69,2	61,5	30,8
44	0,0	69,2	69,2	61,5	34,6
45	0,0	57,7	57,7	65,4	34,6
46	0,0	69,2	69,2	57,7	38,5
47	0,0	69,2	69,2	73,1	15,4
48	0,0	65,4	69,2	53,8	23,1
49	0,0	65,4	65,4	69,2	15,4
50	0,0	65,4	57,7	76,9	15,4
Valor médio	0,0	64,8	63,7	62,5	23,0



Precisão dos Classificadores com PCA=50%

E.1 Classificação Binária Descafeinado/Café

Tabela E.1.1 Precisão da classificação binária descafeinado/café com PCA=50% usando os classificadores de árvore de decisão, análise discriminante, regressão logística e *naïve bayes*.

Análise ao minuto	<i>Fine Tree</i>	<i>Medium Tree</i>	<i>Coarse Tree</i>	<i>Lineaar Discriminant</i>	<i>Logist Regression</i>	<i>Naïve Bayes Gaussiane</i>
1	42,3	42,3	46,2	38,5	38,5	46,2
2	38,5	38,5	38,5	42,3	42,3	50,0
3	46,2	46,2	46,2	50,0	50,0	34,6
4	38,5	38,5	42,3	7,7	7,7	50,0
5	34,6	34,6	38,5	38,5	42,3	26,9
6	61,5	61,5	65,4	53,8	53,8	46,2
7	50,0	50,0	50,0	23,1	23,1	38,5
8	42,3	42,3	50,0	42,3	42,3	50,0
9	38,5	38,5	38,5	34,6	34,6	34,6
10	53,8	53,8	53,8	30,8	30,8	11,5
11	46,2	46,2	42,3	34,6	34,6	30,8
12	57,7	57,7	57,7	30,8	30,8	42,3
13	65,4	65,4	65,4	73,1	76,9	73,1
14	57,7	57,7	57,7	42,3	42,3	38,5
15	50,0	50,0	50,0	38,5	34,6	42,3
16	53,8	53,8	50,0	23,1	26,9	23,1
17	65,4	65,4	61,5	65,4	65,4	53,8
18	26,9	26,9	23,1	3,8	3,8	26,9
19	38,5	38,5	42,3	34,6	38,5	30,8
20	57,7	57,7	57,7	15,4	23,1	11,5
21	38,5	38,5	38,5	38,5	42,3	53,8
22	46,2	46,2	46,2	57,7	57,7	50,0

Continua na próxima página

23	23,1	23,1	23,1	3,8	3,8	26,9
24	46,2	46,2	46,2	26,9	26,9	38,5
25	38,5	38,5	30,8	46,2	46,2	46,2
26	61,5	61,5	61,5	46,2	46,2	50,0
27	26,9	26,9	26,9	11,5	11,5	7,7
28	42,3	42,3	38,5	38,5	38,5	50,0
29	38,5	38,5	38,5	69,2	65,4	57,7
30	30,8	30,8	30,8	23,1	23,1	42,3
31	57,7	57,7	57,7	53,8	53,8	46,2
32	46,2	46,2	46,2	46,2	46,2	69,2
33	57,7	57,7	57,7	7,7	7,7	50,0
34	42,3	42,3	42,3	38,5	38,5	38,5
35	38,5	38,5	42,3	46,2	50,0	38,5
36	38,5	38,5	38,5	23,1	23,1	15,3
37	34,6	34,6	34,6	46,2	46,2	46,2
38	53,8	53,8	53,8	38,5	42,3	42,3
39	38,5	38,5	38,5	42,3	42,3	30,8
40	23,1	23,1	23,1	34,6	30,8	42,3
41	53,8	53,8	53,8	53,8	53,8	50,0
42	50,0	50,0	50,0	65,4	65,4	57,7
43	69,2	69,2	69,2	65,4	61,5	57,7
44	50,0	50,0	50,0	46,2	46,2	61,5
45	34,6	34,6	34,6	57,7	57,7	42,3
46	42,3	42,3	46,2	53,8	53,8	53,8
47	57,7	57,7	57,7	30,8	30,8	38,5
48	73,1	73,1	73,1	42,3	42,3	50,0
49	53,8	53,8	53,8	53,8	57,7	57,7
50	57,7	57,7	57,7	19,2	19,2	38,5
Valor médio	46,6	46,6	46,8	39,0	39,5	42,2

Tabela E.1.2 Precisão da classificação binária descafeinado/café com PCA=50% usando os classificadores SVM.

Análise ao minuto	<i>Linear SVM</i>	<i>Quadratic SVM</i>	<i>Cubic SVM</i>	<i>Fine Gaussian SVM</i>	<i>Medium Gaussian SVM</i>	<i>Coarse Gaussian SVM</i>
1	34,6	38,5	23,1	3,8	0,0	0,0
2	30,8	53,8	61,5	30,8	0,0	0,0
3	53,8	30,8	23,1	38,5	0,0	0,0
4	19,2	42,3	34,6	0,0	0,0	0,0

Continua na próxima página

5	42,3	15,4	34,6	11,5	0,0	0,0
6	38,5	50,0	46,2	42,3	0,0	0,0
7	23,1	46,2	34,6	19,2	0,0	0,0
8	46,2	38,5	38,5	46,2	0,0	0,0
9	42,3	53,8	42,3	30,8	0,0	0,0
10	23,1	34,6	38,5	3,8	0,0	0,0
11	34,6	30,8	30,8	26,9	0,0	0,0
12	42,3	38,5	50,0	11,5	0,0	0,0
13	65,4	73,1	61,5	76,9	0,0	0,0
14	42,3	38,5	46,2	38,5	0,0	0,0
15	34,6	57,7	61,5	26,9	0,0	0,0
16	30,8	34,6	34,6	15,4	0,0	0,0
17	53,8	46,2	53,8	46,2	0,0	0,0
18	3,8	34,6	19,2	0,0	0,0	0,0
19	26,9	26,9	23,1	3,8	0,0	0,0
20	23,1	38,5	46,2	26,9	0,0	0,0
21	46,2	61,5	57,7	57,7	0,0	0,0
22	53,8	53,8	50,0	38,5	0,0	0,0
23	11,5	46,2	42,3	23,1	0,0	0,0
24	34,6	34,6	30,8	11,5	0,0	0,0
25	53,8	38,5	42,3	46,2	0,0	0,0
26	50,0	53,8	53,8	46,2	0,0	0,0
27	7,7	30,8	30,8	0,0	0,0	0,0
28	26,9	42,3	42,3	34,6	0,0	0,0
29	76,9	50,0	46,2	65,4	0,0	0,0
30	11,5	65,4	53,8	46,2	0,0	0,0
31	65,4	50,0	46,2	61,5	0,0	0,0
32	46,2	53,8	61,5	53,8	0,0	0,0
33	7,7	57,7	42,3	7,7	0,0	0,0
34	30,8	30,8	50,0	0,0	0,0	0,0
35	38,5	26,9	42,3	7,7	0,0	23,1
36	15,4	42,3	38,5	15,4	0,0	0,0
37	50,0	50,0	53,8	38,5	0,0	0,0
38	30,8	38,5	42,3	23,1	0,0	0,0
39	26,9	42,3	50,0	7,7	0,0	0,0
40	42,3	42,3	38,5	26,9	0,0	0,0
41	65,4	61,5	50,0	42,3	0,0	0,0
42	61,5	53,8	38,5	57,7	0,0	0,0
43	65,4	38,5	34,6	46,2	0,0	0,0
44	46,2	30,8	46,2	30,8	0,0	0,0

Continua na próxima página

45	65,4	59,0	34,6	50,0	0,0	0,0
46	65,4	46,2	26,9	46,2	0,0	0,0
47	38,5	50,0	50,0	19,2	0,0	0,0
48	26,9	42,3	57,7	34,6	0,0	0,0
49	61,5	53,8	61,5	57,7	0,0	0,0
50	23,1	69,2	57,7	3,8	0,0	0,0
Valor médio	39,2	44,8	43,5	30,0	0,0	0,5

Tabela E.1.3 Precisão da classificação binária descafeinado/café com PCA=50% usando os classificadores KNN.

Análise ao minuto	<i>Fine KNN</i>	<i>Medium KNN</i>	<i>Coarse KNN</i>	<i>Cosine KNN</i>	<i>Cubic KNN</i>	<i>Weighted KNN</i>
1	38,5	34,6	0,0	46,2	38,5	26,9
2	65,4	38,5	0,0	34,6	34,6	50,0
3	34,6	38,5	0,0	42,3	38,5	30,8
4	38,5	26,9	0,0	26,9	26,9	34,6
5	30,8	38,5	0,0	30,8	34,6	23,1
6	42,3	42,3	0,0	46,2	42,3	42,3
7	30,8	50,0	0,0	26,9	53,8	42,3
8	30,8	46,2	0,0	34,6	34,6	30,8
9	53,8	46,2	0,0	23,1	46,2	46,2
10	38,5	30,8	0,0	30,8	34,6	30,8
11	30,8	38,5	0,0	46,2	50,0	34,6
12	53,8	46,2	0,0	46,2	50,0	50,0
13	76,9	61,5	0,0	65,4	57,7	76,9
14	57,7	42,3	0,0	46,2	46,2	46,2
15	53,8	46,2	0,0	42,3	34,6	53,8
16	23,1	30,8	0,0	26,9	34,6	26,9
17	42,3	61,5	0,0	30,8	53,8	57,7
18	19,2	19,2	0,0	23,1	19,2	23,1
19	26,9	30,8	0,0	30,8	30,8	23,1
20	50,0	34,6	0,0	30,8	26,9	38,5
21	53,8	46,2	0,0	42,3	38,5	50,0
22	57,7	23,1	0,0	30,8	26,9	53,8
23	19,2	38,5	0,0	15,4	30,8	26,9
24	23,1	30,8	0,0	38,5	30,8	23,1
25	42,3	46,2	0,0	42,3	42,3	50,0
26	46,2	50,0	0,0	53,8	53,8	53,8

Continua na próxima página

27	19,2	11,5	7,7	19,2	26,9	34,6
28	50,0	26,9	0,0	50,0	30,8	38,5
29	50,0	61,5	0,0	53,8	53,8	57,7
30	46,2	38,5	0,0	26,9	30,8	50,0
31	53,8	42,3	0,0	30,8	42,3	50,0
32	50,0	42,3	0,0	50,0	42,3	57,7
33	42,3	30,8	0,0	30,8	26,9	38,5
34	30,8	30,8	0,0	42,3	26,9	26,9
35	23,1	15,4	0,0	23,1	19,2	23,1
36	50,0	26,9	0,0	34,6	19,2	42,3
37	38,5	46,2	0,0	42,3	42,3	42,3
38	46,2	42,3	0,0	57,7	23,1	46,2
39	53,8	30,8	0,0	42,3	30,8	50,0
40	42,3	30,8	0,0	42,3	34,6	34,6
41	42,3	30,8	0,0	42,3	34,6	34,6
42	46,2	61,5	0,0	57,7	61,5	38,5
43	38,5	46,2	0,0	50,0	46,2	46,2
44	69,2	30,8	0,0	42,3	30,8	65,4
45	38,5	46,2	0,0	46,2	50,0	26,9
46	42,3	53,8	0,0	53,8	61,5	38,5
47	57,7	15,4	0,0	26,9	19,2	42,3
48	53,8	38,5	0,0	38,5	30,8	42,3
49	65,4	57,7	0,0	50,0	65,4	61,5
50	46,2	11,5	0,0	19,2	11,5	34,6
Valor médio	43,5	38,2	0,2	38,5	37,5	41,4

Tabela E.1.4 Precisão da classificação binária descafeinado/café com PCA=50% usando os classificadores *Ensemble*.

Análise ao minuto	<i>Boosted Tress</i>	<i>Bagged Trees</i>	<i>Subspace Discriminant</i>	<i>Subspace KNN</i>	<i>Rusboosted Trees</i>
1	0,0	34,6	30,8	34,6	26,9
2	0,0	50,0	38,5	69,2	15,4
3	0,0	42,3	50,0	26,9	15,4
4	0,0	38,5	3,8	26,9	38,5
5	0,0	30,8	26,9	26,9	26,9
6	0,0	30,8	53,8	34,6	26,9
7	0,0	46,2	15,4	30,8	30,8
8	0,0	30,8	38,5	38,5	19,2
Continua na próxima página					

9	0,0	50,0	34,6	53,8	7,7
10	0,0	38,5	19,2	50,0	19,2
11	0,0	30,8	30,8	26,9	26,9
12	0,0	61,5	19,2	50,0	15,4
13	0,0	73,1	73,1	57,7	19,2
14	0,0	53,8	38,5	50,0	38,5
15	0,0	65,4	38,5	42,3	15,4
16	0,0	30,8	19,2	46,2	30,8
17	0,0	61,5	57,7	65,4	26,9
18	0,0	30,8	3,8	23,1	30,8
19	0,0	38,5	26,9	42,3	26,9
20	0,0	57,7	15,4	57,7	23,1
21	0,0	34,6	38,5	57,7	23,1
22	0,0	42,3	57,7	50,0	26,9
23	0,0	34,6	3,8	19,2	15,4
24	0,0	53,8	19,2	42,3	19,2
25	0,0	53,8	46,2	50,0	19,2
26	0,0	53,8	46,2	50,0	34,6
27	0,0	34,6	3,8	34,6	30,8
28	0,0	50,0	38,5	42,3	30,8
29	0,0	53,8	69,2	57,7	30,8
30	0,0	26,9	19,2	42,3	26,9
31	0,0	61,5	53,8	46,2	30,8
32	0,0	57,7	42,3	69,2	15,4
33	0,0	46,2	7,7	42,3	34,6
34	0,0	53,8	38,5	46,2	7,7
35	0,0	19,2	38,5	23,1	23,1
36	0,0	57,7	23,1	46,2	11,5
37	0,0	50,0	46,2	42,3	15,4
38	0,0	57,7	34,6	46,2	38,5
39	0,0	38,5	42,3	42,3	19,2
40	0,0	23,1	30,8	46,2	15,4
41	0,0	34,6	30,8	46,2	7,7
42	0,0	65,4	65,4	38,5	34,6
43	0,0	46,2	61,5	53,8	23,1
44	0,0	69,2	46,2	65,4	7,7
45	0,0	19,2	50,0	34,6	26,9
46	0,0	46,2	53,8	30,8	15,4
47	0,0	57,7	30,8	50,0	42,3
48	0,0	61,5	42,3	46,2	38,5

Continua na próxima página

49	0,0	46,2	50,0	61,5	23,1
50	0,0	38,5	19,2	42,3	34,6
Valor médio	0,0	45,7	35,7	44,4	24,1

E.2 Classificação Binária OF_placebo/OF_cafeína

Tabela E.2.1 Precisão da classificação binária OF_placebo/OF_cafeína com PCA=50% usando os classificadores de árvore de decisão, análise discriminante, regressão logística e naïve bayes.

Análise ao minuto	<i>Fine Tree</i>	<i>Medium Tree</i>	<i>Coarse Tree</i>	<i>Lineaar Discriminant</i>	<i>Logist Regression</i>	<i>Naïve Bayes Gaussiane</i>
1	76,9	76,9	76,9	73,1	73,1	69,2
2	57,7	57,7	57,7	65,4	61,5	69,2
3	69,2	69,2	69,2	65,4	61,5	57,7
4	65,4	65,4	65,4	61,5	61,5	6,5
5	57,7	57,7	57,7	57,7	57,7	61,5
6	61,5	61,5	61,5	50,0	50,0	61,5
7	53,8	53,8	53,8	53,8	53,8	57,7
8	53,8	53,8	53,8	57,7	57,7	53,8
9	69,2	69,2	69,2	65,4	65,4	61,5
10	61,5	61,5	61,5	73,1	65,4	69,2
11	57,7	57,7	57,7	61,5	61,5	69,2
12	61,5	61,5	61,5	69,2	65,4	50,0
13	84,6	84,6	84,6	61,5	61,5	61,5
14	76,9	76,9	76,9	61,5	46,2	46,2
15	61,5	61,5	53,8	57,7	61,5	69,2
16	53,8	53,8	53,8	65,4	65,4	53,8
17	65,4	65,4	65,4	69,2	73,1	61,5
18	69,2	69,2	73,1	61,5	61,5	57,7
19	69,2	69,2	69,2	65,4	65,4	57,7
20	61,5	61,5	61,5	69,2	69,2	69,2
21	57,7	57,7	57,7	50,0	53,8	53,8
22	69,2	69,2	69,2	69,2	69,2	73,1
23	65,4	65,4	65,4	73,1	73,1	69,2
24	69,2	69,2	69,2	69,2	69,2	69,2
25	61,5	61,5	61,5	57,7	61,5	57,7
26	73,1	73,1	76,9	65,4	65,4	69,2

Continua na próxima página

27	57,7	57,7	57,7	61,5	61,5	61,5
28	69,2	69,2	69,2	65,4	65,4	65,4
29	65,4	65,4	65,4	69,2	84,6	69,2
30	73,1	73,1	73,1	65,4	65,4	65,4
31	88,5	88,5	88,5	61,5	57,7	69,2
32	76,9	76,9	76,9	73,1	73,1	69,2
33	69,2	69,2	69,2	76,9	73,1	53,8
34	73,1	73,1	73,1	69,2	73,1	61,5
35	53,8	53,8	53,8	69,2	69,2	61,5
36	80,8	80,8	80,8	80,8	76,9	76,9
37	61,5	61,5	61,5	61,5	61,5	61,5
38	57,7	57,7	57,7	61,5	61,5	61,5
39	46,2	46,2	46,2	61,5	61,5	50,0
40	69,2	69,2	69,2	69,2	69,2	73,1
41	61,5	61,5	61,5	69,2	69,2	50,0
42	69,2	69,2	69,2	65,4	65,4	69,2
43	69,2	69,2	80,8	69,2	73,1	53,8
44	76,9	76,9	76,9	76,9	73,1	69,2
45	65,4	65,4	65,4	61,5	61,5	57,7
46	57,7	57,7	57,7	65,4	73,1	65,4
47	76,9	76,9	76,9	69,2	69,2	73,1
48	73,1	73,1	73,1	61,5	61,5	65,4
49	84,6	84,6	84,6	65,4	65,4	61,5
50	76,9	76,9	76,9	57,7	57,7	69,2
Valor médio	66,8	66,8	67,0	65,1	65,1	61,8

Tabela E.2.2 Precisão da classificação binária OF_placebo/OF_cafeína com PCA=50% usando os classificadores SVM.

Análise ao minuto	<i>Linear SVM</i>	<i>Quadratic SVM</i>	<i>Cubic SVM</i>	<i>Fine Gaussian SVM</i>	<i>Medium Gaussian SVM</i>	<i>Coarse Gaussian SVM</i>
1	65,4	53,8	57,7	76,9	0,0	0,0
2	76,9	76,9	73,1	76,9	0,0	0,0
3	61,5	69,2	65,4	65,4	0,0	0,0
4	69,2	73,1	69,2	73,1	0,0	0,0
5	61,5	50,0	61,5	61,5	0,0	0,0
6	53,8	53,8	65,4	73,1	0,0	0,0
7	57,7	69,2	61,5	50,0	0,0	0,0
8	61,5	57,7	46,2	65,4	0,0	0,0

Continua na próxima página

9	73,1	76,9	80,8	69,2	0,0	0,0
10	73,1	69,2	50,0	76,9	0,0	0,0
11	61,5	50,0	53,8	69,2	0,0	0,0
12	69,2	73,1	80,8	73,1	0,0	0,0
13	57,7	46,2	57,7	50,0	0,0	0,0
14	73,1	61,5	53,8	76,9	0,0	0,0
15	61,5	61,5	65,4	69,2	0,0	0,0
16	61,5	53,8	57,7	65,4	0,0	0,0
17	69,2	57,7	57,7	61,5	0,0	0,0
18	65,4	80,8	65,4	65,4	0,0	0,0
19	69,2	61,5	69,2	69,2	0,0	0,0
20	69,2	76,9	65,4	61,5	0,0	0,0
21	46,2	65,4	73,1	65,4	0,0	0,0
22	65,4	57,7	38,5	65,4	0,0	0,0
23	73,1	73,1	65,4	73,1	0,0	0,0
24	69,2	73,1	69,2	73,1	0,0	0,0
25	65,4	73,1	76,9	61,5	0,0	0,0
26	73,1	69,2	57,7	73,1	0,0	0,0
27	69,2	73,1	65,4	69,2	0,0	0,0
28	57,7	61,5	50,0	69,2	0,0	0,0
29	69,2	69,2	69,2	73,1	0,0	0,0
30	65,4	76,9	76,9	69,2	0,0	0,0
31	65,4	61,5	69,2	69,2	0,0	0,0
32	80,8	69,2	69,2	76,9	0,0	0,0
33	76,9	73,1	69,2	76,9	0,0	0,0
34	65,4	53,8	57,7	73,1	0,0	0,0
35	65,4	65,4	65,4	65,4	0,0	0,0
36	80,8	73,1	73,1	76,9	0,0	0,0
37	53,8	69,2	73,1	69,2	0,0	0,0
38	61,5	61,5	69,2	61,5	0,0	0,0
39	53,8	50,0	57,7	57,7	0,0	0,0
40	73,1	57,7	50,0	73,1	0,0	0,0
41	69,2	61,5	61,5	69,2	0,0	0,0
42	61,5	57,7	73,1	61,5	0,0	0,0
43	69,2	73,1	73,1	65,4	0,0	0,0
44	76,9	69,2	54,8	73,1	0,0	0,0
45	65,4	69,2	61,5	76,9	0,0	0,0
46	65,4	65,4	53,8	65,4	0,0	0,0
47	65,4	69,2	80,8	57,7	0,0	0,0
48	65,4	61,5	69,2	69,2	0,0	0,0

Continua na próxima página

49	69,2	69,2	69,2	80,8	0,0	0,0
50	57,7	80,8	73,1	65,4	0,0	0,0
Valor médio	66,1	65,5	64,5	68,5	0,0	0,0

Tabela E.2.3 Precisão da classificação binária OF_placebo/OF_cafeína com PCA=50% usando os classificadores KNN.

Análise ao minuto	<i>Fine KNN</i>	<i>Medium KNN</i>	<i>Coarse KNN</i>	<i>Cosine KNN</i>	<i>Cubic KNN</i>	<i>Weighted KNN</i>
1	57,7	69,2	0,0	73,1	69,2	57,7
2	53,8	73,1	0,0	73,1	76,9	65,4
3	65,4	73,1	0,0	69,2	73,1	65,4
4	73,1	73,1	0,0	65,4	73,1	69,2
5	42,3	42,3	0,0	50,0	42,3	50,0
6	61,5	65,4	0,0	50,0	61,5	65,4
7	61,5	50,0	0,0	53,8	46,2	57,7
8	53,8	61,5	0,0	61,5	61,5	42,3
9	80,8	69,2	0,0	65,4	69,2	76,9
10	50,0	76,9	0,0	73,1	76,9	57,7
11	38,5	46,2	0,0	69,2	50,0	57,7
12	76,9	73,1	0,0	73,1	73,1	80,8
13	57,7	53,8	0,0	61,5	50,0	38,5
14	61,5	73,1	0,0	61,5	73,1	53,8
15	65,4	69,2	0,0	65,4	57,7	61,5
16	46,2	65,4	0,0	61,5	61,5	50,0
17	61,5	61,5	0,0	69,2	61,5	53,8
18	57,7	65,4	0,0	69,2	65,4	57,7
19	69,2	61,5	0,0	50,0	61,5	61,5
20	61,5	65,4	0,0	57,7	61,5	57,7
21	73,1	42,3	0,0	57,7	42,3	69,2
22	53,8	73,1	0,0	69,2	73,1	57,7
23	61,5	73,1	0,0	69,2	73,1	73,1
24	69,2	69,2	0,0	73,1	73,1	69,2
25	73,1	65,4	0,0	65,4	65,4	69,2
26	53,8	73,1	0,0	34,6	73,1	53,8
27	65,4	69,2	0,0	57,7	69,2	61,5
28	57,7	61,5	0,0	65,4	50,0	61,5
29	61,5	73,1	0,0	76,9	76,9	73,1
30	69,2	69,2	0,0	65,4	69,2	65,4

Continua na próxima página

31	76,9	57,7	0,0	65,4	50,0	69,2
32	69,2	80,8	0,0	76,9	76,9	73,1
33	73,1	76,9	0,0	76,9	76,9	69,2
34	65,4	61,5	0,0	65,4	61,5	65,4
35	65,4	57,7	0,0	65,4	57,7	61,5
36	76,9	65,4	0,0	76,9	69,2	73,1
37	69,2	69,2	0,0	65,4	73,1	69,2
38	65,4	53,8	0,0	65,4	57,7	73,1
39	65,4	65,4	0,0	69,2	65,4	65,4
40	53,8	76,9	0,0	73,1	73,1	57,7
41	50,0	73,1	0,0	65,4	76,9	61,5
42	73,1	46,2	0,0	50,0	46,2	65,4
43	73,1	61,5	0,0	53,8	61,5	61,5
44	65,4	73,1	0,0	69,2	73,1	65,4
45	57,7	73,1	0,0	69,2	73,1	61,5
46	57,7	73,1	0,0	73,1	69,2	69,2
47	80,8	65,4	0,0	65,4	65,4	69,2
48	61,5	50,0	0,0	53,8	53,8	57,7
49	76,9	73,1	0,0	76,9	73,1	80,8
50	76,9	73,1	0,0	73,1	73,1	69,2
Valor médio	63,8	65,7	0,0	65,1	65,2	63,5

Tabela E.2.4 Precisão da classificação binária OF_placebo/OF_cafeína com PCA=50% usando os classificadores *Ensemble*.

Análise ao minuto	<i>Boosted Tress</i>	<i>Bagged Trees</i>	<i>Subspace Discriminant</i>	<i>Subspace KNN</i>	<i>Rusboosted Trees</i>
1	0,0	69,2	69,2	57,7	15,4
2	0,0	57,7	65,4	65,4	46,2
3	0,0	57,7	61,5	61,5	23,1
4	0,0	57,7	50,0	61,5	30,8
5	0,0	50,0	53,8	46,2	34,6
6	0,0	65,4	46,2	65,4	23,1
7	0,0	57,7	53,8	53,8	26,9
8	0,0	53,8	57,7	50,0	34,6
9	0,0	65,4	57,7	73,1	19,2
10	0,0	53,8	69,2	69,2	34,6
11	0,0	65,4	61,5	57,7	46,2
12	0,0	69,2	61,5	69,2	23,1

Continua na próxima página

13	0,0	57,7	61,5	57,7	38,5
14	0,0	69,2	57,7	53,8	30,8
15	0,0	61,5	61,5	57,7	15,4
16	0,0	50,0	53,8	53,8	19,2
17	0,0	61,5	65,4	61,5	19,2
18	0,0	69,2	57,7	50,0	34,6
19	0,0	65,4	65,4	61,5	15,4
20	0,0	69,2	61,5	53,8	46,2
21	0,0	57,7	50,0	69,2	19,2
22	0,0	80,8	69,2	61,5	11,5
23	0,0	65,4	73,1	61,5	34,6
24	0,0	69,2	65,4	65,4	19,2
25	0,0	69,2	57,7	76,9	26,9
26	0,0	53,8	65,4	53,8	38,5
27	0,0	53,8	61,5	46,2	30,8
28	0,0	69,2	65,4	57,7	11,5
29	0,0	61,5	73,1	65,4	19,2
30	0,0	65,4	65,4	69,2	30,8
31	0,0	57,7	57,7	73,1	34,6
32	0,0	73,1	73,1	69,2	34,6
33	0,0	65,4	69,2	65,4	15,4
34	0,0	73,1	57,7	57,7	34,6
35	0,0	61,5	61,5	69,2	19,2
36	0,0	73,1	76,9	69,2	19,2
37	0,0	57,7	57,7	53,8	23,1
38	0,0	61,5	61,5	53,8	26,9
39	0,0	61,5	61,5	84,6	15,4
40	0,0	61,5	61,5	50,0	26,9
41	0,0	69,2	65,4	57,7	19,2
42	0,0	69,2	65,4	73,1	19,2
43	0,0	65,4	69,2	57,7	46,2
44	0,0	69,2	73,1	57,7	30,8
45	0,0	61,5	57,7	53,8	23,1
46	0,0	61,5	69,2	61,5	26,9
47	0,0	80,8	65,4	69,2	26,9
48	0,0	65,4	61,5	80,8	3,8
49	0,0	76,9	65,4	69,2	19,2
50	0,0	73,1	57,7	65,4	15,4
Valor médio	0,0	64,2	62,5	62,0	26,0



Precisão dos Classificadores com PCA=20%

F.1 Classificação Binária Descafeinado/Café

Tabela F.1.1 Precisão da classificação binária descafeinado/café com PCA=20% usando os classificadores de árvore de decisão, análise discriminante, regressão logística e *naïve bayes*.

Análise ao minuto	<i>Fine Tree</i>	<i>Medium Tree</i>	<i>Coarse Tree</i>	<i>Lineaar Discriminant</i>	<i>Logist Regression</i>	<i>Naïve Bayes Gaussiane</i>
1	38,5	38,5	38,5	46,2	46,2	50,0
2	23,1	23,1	23,1	53,8	53,8	53,8
3	46,2	46,2	38,5	46,2	46,2	50,0
4	38,5	38,5	42,3	3,8	7,7	3,8
5	38,5	38,5	38,5	0,0	0,0	34,6
6	61,5	61,5	57,7	53,8	57,7	46,2
7	34,6	34,6	34,6	0,0	0,0	19,2
8	38,5	38,5	38,5	38,5	38,5	46,2
9	7,7	7,7	3,8	3,8	7,7	30,8
10	61,5	61,5	61,5	0,0	0,0	7,7
11	46,2	46,2	38,5	0,0	0,0	0,0
12	30,8	30,8	11,5	34,6	34,6	50,0
13	34,6	34,6	42,3	42,3	46,2	38,5
14	46,2	46,2	38,5	19,2	26,9	26,9
15	23,1	23,1	15,4	0,0	0,0	0,0
16	30,8	30,8	19,2	0,0	0,0	0,0
17	53,8	53,8	50,0	30,8	30,8	38,5
18	50,0	50,0	38,5	0,0	0,0	57,7
19	38,5	38,5	34,6	26,9	30,8	23,1
20	65,4	65,4	65,4	15,4	23,1	38,5
21	42,3	42,3	42,3	19,2	23,1	42,3
22	53,8	53,8	57,7	50,0	50,0	46,2

Continua na próxima página

23	30,8	30,8	34,6	0,0	0,0	23,1
24	57,7	57,7	57,7	0,0	0,0	57,7
25	34,6	34,6	34,6	46,2	46,2	53,8
26	50,0	50,0	50,0	46,2	46,2	46,2
27	38,5	38,5	23,1	0,0	0,0	3,8
28	50,0	50,0	53,8	38,5	42,3	46,2
29	61,5	61,5	61,5	3,8	3,8	3,8
30	38,5	38,5	38,5	0,0	0,0	34,6
31	65,4	65,4	65,4	53,8	53,8	46,2
32	53,8	53,8	53,8	30,8	34,6	50,0
33	42,3	42,3	42,3	0,0	0,0	0,0
34	50,0	50,0	50,0	46,2	46,2	50,0
35	46,2	46,2	50,0	53,8	53,8	46,2
36	50,0	50,0	50,0	0,0	0,0	26,9
37	53,8	53,8	42,3	53,8	53,8	53,8
38	38,5	38,5	30,8	26,9	26,9	46,2
39	65,4	65,4	61,5	0,0	3,8	38,5
40	26,9	26,9	34,6	7,7	7,7	57,7
41	57,7	57,7	57,7	57,7	57,7	57,7
42	30,8	30,8	34,6	50,0	50,0	30,8
43	76,9	76,9	76,9	65,4	69,2	57,7
44	50,0	50,0	50,0	42,3	46,2	53,8
45	53,8	53,8	53,8	57,7	57,7	53,8
46	50,0	50,0	38,5	46,2	46,2	38,5
47	53,8	53,8	57,7	38,5	38,5	46,2
48	50,0	50,0	50,0	7,7	7,7	30,8
49	46,2	46,2	46,2	0,0	0,0	50,0
50	69,2	69,2	69,2	38,5	38,5	53,8
Valor médio	45,9	45,9	44,0	25,9	27,1	37,2

Tabela F.1.2 Precisão da classificação binária descafeinado/café com PCA=20% usando os classificadores SVM.

Análise ao minuto	<i>Linear SVM</i>	<i>Quadratic SVM</i>	<i>Cubic SVM</i>	<i>Fine Gaussian SVM</i>	<i>Medium Gaussian SVM</i>	<i>Coarse Gaussian SVM</i>
1	53,8	38,5	42,3	7,7	0,0	0,0
2	50,0	46,2	42,3	42,3	0,0	0,0
3	46,2	34,6	46,2	42,3	0,0	0,0
4	3,8	7,7	50,0	0,0	0,0	0,0

Continua na próxima página

5	0,0	46,2	53,8	0,0	0,0	0,0
6	50,0	57,7	57,7	46,2	0,0	0,0
7	0,0	7,7	34,6	0,0	0,0	0,0
8	42,3	23,1	34,6	0,0	0,0	0,0
9	0,0	30,8	38,5	0,0	0,0	0,0
10	0,0	46,2	38,5	0,0	0,0	0,0
11	0,0	0,0	53,8	0,0	0,0	0,0
12	42,3	11,5	53,8	0,0	0,0	0,0
13	46,2	19,2	38,5	0,0	0,0	0,0
14	11,5	42,3	26,9	0,0	0,0	0,0
15	0,0	0,0	30,8	0,0	0,0	0,0
16	0,0	0,0	42,3	0,0	0,0	0,0
17	42,3	26,9	50,0	7,7	0,0	0,0
18	0,0	61,5	26,9	0,0	0,0	0,0
19	7,7	26,9	46,2	0,0	0,0	0,0
20	3,8	46,2	42,3	0,0	0,0	0,0
21	42,3	46,2	38,5	0,0	0,0	0,0
22	46,2	46,2	34,6	0,0	0,0	0,0
23	0,0	38,5	46,2	0,0	0,0	0,0
24	0,0	61,5	65,4	0,0	0,0	0,0
25	53,8	50,0	26,9	0,0	0,0	0,0
26	46,2	38,5	42,3	34,6	0,0	0,0
27	0,0	0,0	30,8	0,0	0,0	0,0
28	46,2	50,0	34,6	0,0	0,0	0,0
29	3,8	3,8	42,3	0,0	0,0	0,0
30	0,0	50,0	38,5	0,0	0,0	0,0
31	69,2	57,7	61,5	57,7	0,0	0,0
32	53,8	65,4	57,7	38,5	0,0	0,0
33	0,0	11,5	50,0	0,0	0,0	0,0
34	23,1	53,8	46,2	3,8	0,0	0,0
35	53,8	42,3	57,7	30,8	0,0	0,0
36	0,0	42,3	42,3	0,0	0,0	0,0
37	57,7	53,8	30,8	50,0	0,0	0,0
38	3,8	42,3	50,0	0,0	0,0	0,0
39	0,0	38,5	26,9	0,0	0,0	0,0
40	3,8	61,5	26,9	3,8	3,8	3,8
41	61,5	53,8	57,7	61,5	0,0	0,0
42	34,6	50,0	42,3	0,0	0,0	0,0
43	65,4	46,2	50,0	57,7	0,0	0,0
44	42,3	50,0	42,3	38,5	0,0	0,0

Continua na próxima página

45	53,8	38,5	46,2	46,2	0,0	0,0
46	38,5	15,4	50,0	15,4	0,0	0,0
47	42,3	61,5	42,3	11,5	0,0	0,0
48	7,7	50,0	53,8	3,8	0,0	0,0
49	0,0	57,7	53,8	0,0	0,0	0,0
50	38,5	61,5	53,8	3,8	0,0	0,0
Valor médio	25,8	38,2	43,8	12,1	0,1	0,1

Tabela F.1.3 Precisão da classificação binária descafeinado/café com PCA=20% usando os classificadores KNN.

Análise ao minuto	<i>Fine KNN</i>	<i>Medium KNN</i>	<i>Coarse KNN</i>	<i>Cosine KNN</i>	<i>Cubic KNN</i>	<i>Weighted KNN</i>
1	46,2	42,3	0,0	50,0	42,3	38,5
2	46,2	38,5	0,0	50,0	38,5	46,2
3	30,8	57,7	0,0	42,3	57,7	34,6
4	50,0	38,5	0,0	50,0	38,5	50,0
5	38,5	50,0	0,0	50,0	50,0	38,5
6	69,2	57,7	0,0	42,3	57,7	65,4
7	38,5	34,6	0,0	50,0	34,6	38,5
8	57,7	34,6	0,0	50,0	34,6	50,0
9	26,9	30,8	0,0	42,3	30,8	30,8
10	53,8	34,6	0,0	50,0	34,6	53,8
11	42,3	19,2	0,0	38,5	19,2	42,3
12	46,2	30,8	0,0	50,0	30,8	38,5
13	34,6	38,5	0,0	50,0	38,5	34,6
14	38,5	19,2	0,0	34,6	19,2	38,5
15	42,3	30,8	0,0	42,3	30,8	26,9
16	38,5	38,5	0,0	50,0	38,5	26,9
17	53,8	34,6	0,0	26,9	34,6	53,8
18	65,4	46,2	0,0	50,0	46,2	57,7
19	50,0	34,6	0,0	46,2	34,6	46,2
20	46,2	42,3	0,0	42,3	42,3	42,3
21	53,8	61,5	0,0	50,0	61,5	53,8
22	73,1	42,3	0,0	50,0	42,3	73,1
23	34,6	34,6	0,0	42,3	34,6	34,6
24	42,3	50,0	0,0	50,0	50,0	46,2
25	38,5	34,6	0,0	50,0	34,6	42,3
26	69,2	65,4	0,0	50,0	65,4	73,1

Continua na próxima página

27	42,3	15,4	0,0	50,0	15,4	38,5
28	34,6	42,3	0,0	50,0	42,3	34,6
29	61,5	26,9	0,0	38,5	26,9	61,5
30	34,6	38,5	0,0	50,0	38,5	34,6
31	50,0	57,7	0,0	53,8	53,8	46,2
32	65,4	57,7	0,0	65,4	57,7	53,8
33	38,5	50,0	0,0	38,5	50,0	46,2
34	42,3	42,3	0,0	46,2	42,3	38,5
35	61,5	19,2	0,0	50,0	19,2	53,8
36	53,8	50,0	0,0	38,5	50,0	50,0
37	42,3	38,5	0,0	50,0	38,5	50,0
38	42,3	23,1	0,0	38,5	23,1	42,3
39	42,3	30,8	0,0	30,8	30,8	42,3
40	38,5	30,8	3,8	38,5	30,8	42,3
41	57,7	61,5	0,0	42,3	61,5	53,8
42	42,3	30,8	0,0	50,0	30,8	30,8
43	50,0	61,5	0,0	61,5	53,8	57,7
44	42,3	57,7	0,0	38,5	57,7	42,3
45	57,7	23,1	0,0	50,0	23,1	61,5
46	42,3	30,8	0,0	42,3	26,9	42,3
47	50,0	46,2	0,0	57,7	50,0	50,0
48	42,3	15,4	0,0	38,5	15,4	42,3
49	46,2	53,8	0,0	50,0	53,8	46,2
50	65,4	50,0	0,0	30,8	50,0	65,4
Valor médio	47,5	39,9	0,1	46,0	39,7	46,1

Tabela F.1.4 Precisão da classificação binária descafeinado/café com PCA=20% usando os classificadores *Ensemble*.

Análise ao minuto	<i>Boosted Tress</i>	<i>Bagged Trees</i>	<i>Subspace Discriminant</i>	<i>Subspace KNN</i>	<i>Rusboosted Trees</i>
1	0,0	46,2	46,2	46,2	15,4
2	0,0	42,3	53,8	46,2	23,1
3	0,0	30,8	46,2	30,8	26,9
4	0,0	50,0	3,8	50,0	30,8
5	0,0	38,5	0,0	38,5	38,5
6	0,0	69,2	53,8	69,2	23,1
7	0,0	38,5	0,0	38,5	26,9
8	0,0	57,7	38,5	57,7	34,6

Continua na próxima página

9	0,0	26,9	3,8	26,9	15,4
10	0,0	57,7	0,0	53,8	19,2
11	0,0	42,3	0,0	42,3	30,8
12	0,0	46,2	34,6	46,2	30,8
13	0,0	34,6	42,3	34,6	23,1
14	0,0	46,2	19,2	38,5	19,2
15	0,0	42,3	0,0	42,3	23,1
16	0,0	38,5	0,0	38,5	19,2
17	0,0	50,0	23,1	38,5	15,4
18	0,0	61,5	0,0	65,4	30,8
19	0,0	50,0	26,9	50,0	38,5
20	0,0	46,2	15,4	46,2	15,4
21	0,0	53,8	19,2	53,8	19,2
22	0,0	69,2	50,0	69,2	26,9
23	0,0	34,6	0,0	34,6	26,9
24	0,0	42,3	0,0	42,3	26,9
25	0,0	42,3	46,2	38,5	19,2
26	0,0	69,2	46,2	69,2	15,4
27	0,0	38,5	0,0	42,3	30,8
28	0,0	34,6	38,5	34,6	19,2
29	0,0	61,5	3,8	61,5	23,1
30	0,0	38,5	0,0	38,5	19,2
31	0,0	57,7	46,2	53,8	30,8
32	0,0	65,4	30,8	65,4	34,6
33	0,0	38,5	0,0	38,5	15,4
34	0,0	42,3	46,2	42,3	15,3
35	0,0	61,5	53,8	61,5	38,5
36	0,0	50,0	0,0	50,0	30,8
37	0,0	42,3	53,8	42,3	19,2
38	0,0	42,3	23,1	38,5	19,2
39	0,0	34,6	0,0	34,6	26,9
40	3,8	42,3	7,7	38,5	23,1
41	0,0	50,0	57,7	50,0	34,6
42	0,0	42,3	50,0	42,3	19,2
43	0,0	65,4	53,8	50,0	46,2
44	0,0	46,2	42,3	38,5	23,1
45	0,0	57,7	57,7	57,7	19,2
46	0,0	42,3	46,2	46,2	23,1
47	0,0	57,7	15,4	46,2	23,1
48	0,0	42,3	7,7	46,2	23,1

Continua na próxima página

49	0,0	46,2	0,0	46,2	23,1
50	0,0	65,4	38,5	65,4	19,2
Valor médio	0,1	47,9	24,8	46,8	24,7

F.2 Classificação Binária OF_placebo/OF_cafeína

Tabela F.2.1 Precisão da classificação binária OF_placebo/OF_cafeína com PCA=20% usando os classificadores de árvore de decisão, análise discriminante, regressão logística e naïve bayes.

Análise ao minuto	<i>Fine Tree</i>	<i>Medium Tree</i>	<i>Coarse Tree</i>	<i>Lineaar Discriminant</i>	<i>Logist Regression</i>	<i>Naïve Bayes Gaussiane</i>
1	80,8	80,8	80,8	65,4	65,4	69,2
2	57,7	57,7	57,7	69,2	69,2	73,1
3	69,2	69,2	69,2	69,2	65,4	69,2
4	73,1	73,1	73,1	61,5	61,5	57,7
5	50,0	50,0	50,0	61,5	61,5	65,4
6	61,5	61,5	57,7	65,4	65,4	69,2
7	69,2	69,2	69,2	53,8	53,8	65,4
8	61,5	61,5	61,5	57,7	57,7	65,4
9	76,9	76,9	76,9	61,5	61,5	65,4
10	61,5	61,5	61,5	76,9	65,4	76,9
11	80,8	80,8	80,8	0,0	0,0	57,7
12	53,8	53,8	53,8	69,2	69,2	65,4
13	53,8	53,8	57,7	53,8	53,8	50,0
14	57,7	57,7	57,7	61,5	61,5	46,2
15	53,8	53,8	57,7	15,4	15,4	50,0
16	53,8	53,8	53,8	57,7	57,7	61,5
17	53,8	53,8	57,7	65,4	57,7	73,1
18	73,1	73,1	73,1	65,4	65,4	65,4
19	73,1	73,1	73,1	61,5	61,5	69,2
20	69,2	69,2	69,2	65,4	65,4	65,4
21	65,4	65,4	65,4	57,7	57,7	73,1
22	69,2	69,2	69,2	69,2	69,2	69,2
23	65,4	65,4	65,4	69,2	69,2	69,2
24	73,1	65,4	73,1	69,2	69,2	76,9
25	57,7	65,4	57,7	61,5	61,5	57,7
26	73,1	65,4	73,1	65,4	65,4	69,2

Continua na próxima página

27	53,8	65,4	53,8	53,8	53,8	50,0
28	73,1	65,4	73,1	65,4	65,4	65,4
29	69,2	69,2	69,2	76,9	76,9	73,1
30	73,1	73,1	73,1	65,4	65,4	65,4
31	73,1	73,1	73,1	65,4	65,4	69,2
32	80,8	80,8	80,8	69,2	69,2	69,2
33	61,5	61,5	61,5	61,5	61,5	73,1
34	61,5	61,5	61,5	69,2	69,2	65,4
35	61,5	61,5	61,5	57,7	57,7	65,4
36	69,2	69,2	69,2	80,8	76,9	76,9
37	69,2	69,2	69,2	46,2	46,2	61,5
38	65,4	65,4	65,4	69,2	69,2	73,1
39	65,4	65,4	65,4	0,0	0,0	42,3
40	76,9	76,9	76,9	65,4	65,4	69,2
41	65,4	65,4	65,4	0,0	0,0	0,0
42	69,2	69,2	69,2	53,8	53,8	57,7
43	76,9	76,9	76,9	57,7	57,7	65,4
44	53,8	53,8	57,7	57,7	57,7	65,4
45	73,1	73,1	73,1	65,4	65,4	73,1
46	76,9	76,9	76,9	57,7	57,7	65,4
47	65,4	65,4	65,4	61,5	69,2	61,5
48	69,2	69,2	69,2	15,4	19,2	30,8
49	69,2	69,2	69,2	69,2	69,2	76,9
50	73,1	73,1	73,1	61,5	61,5	73,1
Valor médio	66,7	66,6	66,9	57,9	57,6	63,7

Tabela F.2.2 Precisão da classificação binária OF_placebo/OF_cafeína com PCA=20% usando os classificadores SVM.

Análise ao minuto	<i>Linear SVM</i>	<i>Quadratic SVM</i>	<i>Cubic SVM</i>	<i>Fine Gaussian SVM</i>	<i>Medium Gaussian SVM</i>	<i>Coarse Gaussian SVM</i>
1	69,2	73,1	73,1	76,9	0,0	0,0
2	73,1	76,9	57,7	73,1	0,0	0,0
3	76,9	69,2	61,5	76,9	0,0	0,0
4	61,5	69,2	30,8	61,5	0,0	0,0
5	65,4	69,2	76,9	65,4	0,0	0,0
6	73,1	73,1	61,5	76,9	0,0	0,0
7	53,8	73,1	69,2	65,4	0,0	0,0
8	65,4	73,1	34,6	65,4	0,0	0,0

Continua na próxima página

9	65,4	76,9	69,2	73,1	0,0	0,0
10	69,2	73,1	61,5	76,9	0,0	0,0
11	0,0	57,7	69,2	26,9	0,0	0,0
12	69,2	73,1	73,1	73,1	0,0	0,0
13	57,7	61,5	30,8	53,8	0,0	0,0
14	53,8	65,4	61,5	57,7	0,0	0,0
15	26,9	57,7	53,8	11,5	0,0	0,0
16	57,7	65,4	65,4	65,4	0,0	0,0
17	73,1	73,1	73,1	73,1	0,0	0,0
18	65,4	73,1	57,7	65,4	0,0	0,0
19	73,1	69,2	80,8	76,9	0,0	0,0
20	65,4	73,1	34,6	69,2	0,0	0,0
21	69,2	73,1	69,2	76,9	0,0	0,0
22	69,2	69,2	57,7	76,9	0,0	0,0
23	73,1	69,2	34,6	73,1	0,0	0,0
24	76,9	73,1	46,2	76,9	0,0	0,0
25	57,7	69,2	69,2	65,4	0,0	0,0
26	73,1	76,9	46,2	73,1	0,0	0,0
27	50,0	61,5	57,7	3,8	0,0	0,0
28	65,4	69,2	65,4	76,9	0,0	0,0
29	76,9	65,4	69,2	76,9	0,0	0,0
30	65,4	69,2	69,2	65,4	0,0	0,0
31	69,2	73,1	73,1	73,1	0,0	0,0
32	69,2	80,8	73,1	73,1	0,0	0,0
33	73,1	73,1	73,1	69,2	0,0	0,0
34	69,2	73,1	61,5	73,1	0,0	0,0
35	73,1	73,1	50,0	76,9	0,0	0,0
36	76,9	76,9	65,4	76,9	0,0	0,0
37	50,0	76,9	30,8	57,7	0,0	0,0
38	73,1	73,1	53,8	69,2	0,0	0,0
39	0,0	42,3	73,1	0,0	0,0	0,0
40	76,9	73,1	73,1	76,9	0,0	0,0
41	0,0	0,0	50,0	0,0	0,0	0,0
42	53,8	73,1	76,9	57,7	0,0	0,0
43	61,5	76,9	80,8	69,2	0,0	0,0
44	61,5	69,2	42,3	65,4	0,0	0,0
45	73,1	69,2	46,2	73,1	0,0	0,0
46	61,5	76,9	69,2	61,5	0,0	0,0
47	57,7	57,7	53,8	53,8	0,0	0,0
48	30,8	46,2	65,4	19,2	0,0	0,0

Continua na próxima página

49	80,8	80,8	73,1	80,8	0,0	0,0
50	73,1	73,1	76,9	76,9	0,0	0,0
Valor médio	61,5	68,6	60,8	63,1	0,0	0,0

Tabela F.2.3 Precisão da classificação binária OF_placebo/OF_cafeína com PCA=20% usando os classificadores KNN.

Análise ao minuto	<i>Fine KNN</i>	<i>Medium KNN</i>	<i>Coarse KNN</i>	<i>Cosine KNN</i>	<i>Cubic KNN</i>	<i>Weighted KNN</i>
1	76,9	76,9	0,0	30,8	76,9	76,9
2	69,2	73,1	0,0	30,8	73,1	69,2
3	65,4	80,8	0,0	30,8	80,8	61,5
4	61,5	65,4	0,0	34,6	65,4	61,5
5	53,8	65,4	0,0	30,8	65,4	53,8
6	69,2	76,9	0,0	30,8	76,9	69,2
7	61,5	57,7	0,0	30,8	57,7	61,5
8	53,8	65,4	0,0	30,8	65,4	53,8
9	69,2	73,1	0,0	38,5	73,1	69,2
10	57,7	65,4	0,0	69,2	65,4	57,7
11	73,1	57,7	0,0	65,4	57,7	76,9
12	69,2	73,1	0,0	73,1	73,1	69,2
13	50,0	65,4	0,0	30,8	65,4	50,0
14	57,7	69,2	0,0	73,1	69,2	57,7
15	65,4	46,2	0,0	34,6	46,2	65,4
16	57,7	65,4	0,0	53,8	65,4	61,5
17	76,9	57,7	0,0	50,0	57,7	69,2
18	57,7	65,4	0,0	42,3	65,4	57,7
19	80,8	65,4	0,0	50,0	65,4	80,8
20	65,4	61,5	0,0	50,0	61,5	69,2
21	73,1	73,1	0,0	30,8	73,1	76,9
22	65,4	73,1	0,0	76,9	73,1	65,4
23	61,5	73,1	0,0	30,8	73,1	61,5
24	76,9	73,1	0,0	73,1	73,1	76,9
25	57,7	69,2	0,0	65,4	69,2	61,5
26	53,8	73,1	0,0	30,8	73,1	50,0
27	61,5	57,7	0,0	61,5	57,7	65,4
28	65,4	76,9	0,0	30,8	76,9	69,2
29	61,5	76,9	0,0	80,8	76,9	65,4
30	69,2	65,4	0,0	50,0	65,4	65,4

Continua na próxima página

31	69,2	73,1	0,0	57,7	73,1	69,2
32	69,2	73,1	0,0	69,2	73,1	73,1
33	69,2	73,1	0,0	69,2	73,1	61,5
34	50,0	73,1	0,0	69,2	73,1	57,7
35	57,7	69,2	0,0	30,8	69,2	69,2
36	57,7	76,9	0,0	80,8	76,9	61,5
37	61,5	69,2	0,0	30,8	69,2	65,4
38	53,8	69,2	0,0	30,8	69,2	53,8
39	57,7	53,8	0,0	69,2	53,8	57,7
40	57,7	69,2	0,0	61,5	69,2	57,7
41	57,7	57,7	0,0	38,5	57,7	57,7
42	73,1	57,7	0,0	50,0	57,7	80,8
43	65,4	76,9	0,0	30,8	76,9	61,5
44	46,2	61,5	0,0	50,0	61,5	46,2
45	61,5	73,1	0,0	50,0	73,1	65,4
46	61,5	65,4	0,0	61,5	65,4	65,4
47	53,8	57,7	0,0	73,1	57,7	61,5
48	65,4	61,5	0,0	38,5	61,5	65,4
49	61,5	80,8	0,0	30,8	80,8	65,4
50	61,5	76,9	0,0	30,8	76,9	65,4
Valor médio	63,0	68,2	0,0	48,7	68,2	64,2

Tabela F.2.4 Precisão da classificação binária OF_placebo/OF_cafeína com PCA=20% usando os classificadores *Ensemble*.

Análise ao minuto	<i>Boosted Tress</i>	<i>Bagged Trees</i>	<i>Subspace Discriminant</i>	<i>Subspace KNN</i>	<i>Rusboosted Trees</i>
1	0,0	76,9	65,4	76,9	26,9
2	0,0	69,2	69,2	69,2	34,6
3	0,0	65,4	69,2	65,4	15,4
4	0,0	61,5	61,5	61,5	19,2
5	0,0	53,8	61,5	53,8	34,6
6	0,0	69,2	65,4	69,2	23,1
7	0,0	61,5	53,8	61,5	23,1
8	0,0	53,8	57,7	53,8	23,1
9	0,0	69,2	61,5	69,2	30,8
10	0,0	57,7	76,9	57,7	30,8
11	0,0	73,1	0,0	73,1	15,4
12	0,0	69,2	69,2	69,2	23,1

Continua na próxima página

13	0,0	50,0	53,8	50,0	19,2
14	0,0	57,7	61,5	57,7	26,9
15	0,0	65,4	15,4	65,4	19,2
16	0,0	57,7	57,7	57,7	19,2
17	0,0	76,9	65,4	76,9	19,2
18	0,0	57,7	65,4	57,7	23,1
19	0,0	80,8	61,5	80,8	23,1
20	0,0	65,4	65,4	65,4	19,2
21	0,0	73,1	57,7	73,1	26,9
22	0,0	69,2	69,2	65,4	11,5
23	0,0	61,5	69,2	61,5	23,1
24	0,0	76,9	69,2	76,9	30,8
25	0,0	57,7	61,5	57,7	19,2
26	0,0	53,8	65,4	53,8	26,9
27	0,0	61,5	53,8	61,5	19,2
28	0,0	65,4	65,4	65,4	30,8
29	0,0	61,5	76,9	61,5	26,9
30	0,0	69,2	65,4	69,2	19,2
31	0,0	69,2	65,4	69,2	23,1
32	0,0	69,2	69,2	69,2	23,1
33	0,0	61,5	61,5	69,2	19,2
34	0,0	50,0	69,2	50,0	26,9
35	0,0	57,7	57,7	57,7	19,2
36	0,0	57,7	80,8	57,7	26,9
37	0,0	57,7	46,2	61,5	11,5
38	0,0	57,7	69,2	53,8	26,9
39	0,0	57,7	0,0	57,7	26,9
40	0,0	61,5	65,4	57,7	11,5
41	0,0	57,7	0,0	57,7	23,1
42	0,0	73,1	53,8	73,1	19,2
43	0,0	65,4	57,7	65,4	30,8
44	0,0	46,2	57,7	46,2	30,8
45	0,0	61,5	65,4	61,5	23,1
46	0,0	65,4	57,7	61,5	23,1
47	0,0	53,8	61,5	53,8	15,4
48	0,0	65,4	15,4	65,4	15,4
49	0,0	61,5	69,2	61,5	15,4
50	0,0	61,5	61,5	61,5	23,1
Valor médio	0,0	63,1	57,9	63,0	22,8



Precisão dos Classificadores com PCA=10%

G.1 Classificação Binária Descafeinado/Café

Tabela G.1.1 Precisão da classificação binária descafeinado/café com PCA=10% usando os classificadores de árvore de decisão, análise discriminante, regressão logística e *naïve bayes*.

Análise ao minuto	<i>Fine Tree</i>	<i>Medium Tree</i>	<i>Coarse Tree</i>	<i>Lineaar Discriminant</i>	<i>Logist Regression</i>	<i>Naïve Bayes Gaussiane</i>
1	38,5	38,5	38,5	46,2	46,2	50,0
2	23,1	23,1	23,1	53,8	53,8	53,8
3	46,2	46,2	38,5	46,2	46,2	50,0
4	38,5	38,5	42,3	3,8	7,7	3,8
5	38,5	38,5	38,5	0,0	0,0	34,6
6	61,5	61,5	57,7	53,8	57,7	46,2
7	34,6	34,6	34,6	0,0	0,0	19,2
8	38,5	38,5	38,5	38,5	38,5	46,2
9	7,7	7,7	3,8	3,8	7,7	30,8
10	61,5	61,5	61,5	0,0	0,0	7,7
11	46,2	46,2	38,5	0,0	0,0	0,0
12	30,8	30,8	11,5	34,6	34,6	50,0
13	34,6	34,6	42,3	42,3	46,2	38,5
14	46,2	46,2	38,5	19,2	26,9	26,9
15	23,1	23,1	15,4	0,0	0,0	0,0
16	30,8	30,8	19,2	0,0	0,0	0,0
17	42,3	42,3	38,5	42,3	42,3	42,3
18	50,0	50,0	38,5	0,0	0,0	57,7
19	38,5	38,5	34,6	26,9	30,8	23,1
20	65,4	65,4	65,4	15,4	23,1	38,5
21	42,3	42,3	42,3	19,2	23,1	42,3
22	53,8	53,8	53,8	50,0	50,0	46,2

Continua na próxima página

23	30,8	30,8	34,6	0,0	0,0	23,1
24	57,7	57,7	57,7	0,0	0,0	57,7
25	34,6	34,6	34,6	46,2	46,2	53,8
26	50,0	50,0	50,0	46,2	46,2	46,2
27	38,5	38,5	23,1	0,0	0,0	3,8
28	50,0	50,0	53,8	38,5	42,3	46,2
29	61,5	61,5	61,5	3,8	3,8	3,8
30	38,5	38,5	38,5	0,0	0,0	38,5
31	50,0	50,0	50,0	38,5	38,5	50,0
32	53,8	53,8	53,8	30,8	34,6	50,0
33	42,3	42,3	42,3	0,0	0,0	0,0
34	50,0	50,0	50,0	42,3	42,3	46,2
35	46,2	46,2	50,0	53,8	53,8	46,2
36	53,8	53,8	53,8	0,0	0,0	26,9
37	53,8	53,8	42,3	53,8	53,8	53,8
38	38,5	38,5	30,8	23,1	23,1	46,2
39	57,7	57,7	57,7	0,0	3,8	38,5
40	26,9	26,9	34,6	0,0	0,0	57,7
41	50,0	50,0	50,0	57,7	57,7	57,7
42	30,8	30,8	34,6	50,0	50,0	30,8
43	73,1	73,1	76,9	73,1	73,1	57,7
44	46,2	46,2	46,2	50,0	61,5	57,7
45	53,8	53,8	53,8	57,7	57,7	53,8
46	42,3	42,3	26,9	46,2	46,2	34,6
47	50,0	50,0	50,0	7,7	7,7	26,9
48	42,3	42,3	42,3	0,0	0,0	23,1
49	46,2	46,2	46,2	0,0	0,0	50,0
50	69,2	69,2	69,2	38,5	38,5	53,8
Valor médio	44,6	44,6	42,6	25,1	26,3	36,4

Tabela G.1.2 Precisão da classificação binária descafeinado/café com PCA=10% usando os classificadores SVM.

Análise ao minuto	<i>Linear SVM</i>	<i>Quadratic SVM</i>	<i>Cubic SVM</i>	<i>Fine Gaussian SVM</i>	<i>Medium Gaussian SVM</i>	<i>Coarse Gaussian SVM</i>
1	53,8	38,5	42,3	7,7	0,0	0,0
2	50,0	46,2	42,3	42,3	0,0	0,0
3	46,2	34,6	46,2	42,3	0,0	0,0
4	3,8	7,7	50,0	0,0	0,0	0,0

Continua na próxima página

5	0,0	46,2	53,8	0,0	0,0	0,0
6	50,0	57,7	57,7	46,2	0,0	0,0
7	0,0	7,7	34,6	0,0	0,0	0,0
8	52,3	23,1	34,6	0,0	0,0	0,0
9	0,0	30,8	38,5	0,0	0,0	0,0
10	0,0	46,2	38,5	0,0	0,0	0,0
11	0,0	0,0	53,8	0,0	0,0	0,0
12	42,3	11,5	53,8	0,0	0,0	0,0
13	46,2	19,2	38,5	0,0	0,0	0,0
14	11,5	42,3	26,9	0,0	0,0	0,0
15	0,0	0,0	30,8	0,0	0,0	0,0
16	0,0	0,0	42,3	0,0	0,0	0,0
17	42,3	38,5	46,2	0,0	0,0	0,0
18	0,0	61,5	26,9	0,0	0,0	0,0
19	7,7	26,9	46,2	0,0	0,0	0,0
20	3,8	46,2	42,3	0,0	0,0	0,0
21	42,3	46,2	38,5	0,0	0,0	0,0
22	46,2	42,3	30,8	0,0	0,0	0,0
23	0,0	38,5	46,2	0,0	0,0	0,0
24	0,0	61,5	61,5	0,0	0,0	0,0
25	53,8	50,0	26,9	0,0	0,0	0,0
26	46,2	38,5	46,2	34,6	0,0	0,0
27	0,0	0,0	30,8	0,0	0,0	0,0
28	46,2	50,0	34,6	0,0	0,0	0,0
29	3,8	3,8	42,3	0,0	0,0	0,0
30	0,0	50,0	38,5	0,0	0,0	0,0
31	38,5	42,3	61,5	3,8	0,0	0,0
32	53,8	65,4	57,7	38,5	0,0	0,0
33	0,0	11,5	50,0	0,0	0,0	0,0
34	19,2	53,8	46,2	3,8	0,0	0,0
35	53,8	42,3	57,7	30,8	0,0	0,0
36	0,0	42,3	46,2	0,0	0,0	0,0
37	57,7	53,8	30,8	50,0	0,0	0,0
38	0,0	38,5	50,0	0,0	0,0	0,0
39	0,0	38,5	23,1	0,0	0,0	0,0
40	0,0	61,5	23,1	0,0	0,0	0,0
41	61,5	53,8	61,5	61,5	0,0	0,0
42	34,6	50,0	42,3	0,0	0,0	0,0
43	76,9	53,8	53,8	57,7	0,0	0,0
44	50,0	46,2	50,0	0,0	38,5	0,0

Continua na próxima página

45	53,8	38,5	46,2	46,2	0,0	0,0
46	38,5	11,5	50,0	15,4	0,0	0,0
47	0,0	38,5	30,8	0,0	0,0	0,0
48	0,0	42,3	50,0	0,0	0,0	0,0
49	0,0	57,7	53,8	0,0	0,0	0,0
50	38,5	61,5	53,8	3,8	0,0	0,0
Valor médio	24,5	37,4	43,6	9,7	0,8	0,0

Tabela G.1.3 Precisão da classificação binária descafeinado/café com PCA=10% usando os classificadores KNN.

Análise ao minuto	<i>Fine KNN</i>	<i>Medium KNN</i>	<i>Coarse KNN</i>	<i>Cosine KNN</i>	<i>Cubic KNN</i>	<i>Weighted KNN</i>
1	46,2	42,3	0,0	50,0	42,3	38,5
2	46,2	38,5	0,0	50,0	38,5	46,2
3	30,8	57,7	0,0	42,3	57,7	34,6
4	50,0	38,5	0,0	50,0	38,5	50,0
5	38,5	50,0	0,0	50,0	50,0	38,5
6	69,2	57,7	0,0	42,3	57,7	65,4
7	38,5	34,6	0,0	50,0	34,6	38,5
8	57,7	34,6	0,0	50,0	34,6	50,0
9	26,9	30,8	0,0	42,3	30,8	30,8
10	53,8	34,6	0,0	50,0	34,6	53,8
11	42,3	19,2	0,0	38,5	19,2	42,3
12	46,2	30,8	0,0	50,0	30,8	38,5
13	34,6	38,5	0,0	50,0	38,5	34,6
14	38,5	19,2	0,0	34,6	19,2	38,5
15	42,3	30,8	0,0	42,3	30,8	26,9
16	38,5	38,5	0,0	50,0	38,5	26,9
17	50,0	34,6	0,0	42,3	34,6	53,8
18	65,4	46,2	0,0	50,0	46,2	57,7
19	50,0	34,6	0,0	46,2	34,6	46,2
20	46,2	42,3	0,0	42,3	42,3	42,3
21	53,8	61,5	0,0	50,0	61,5	53,8
22	69,2	42,3	0,0	50,0	42,3	69,2
23	34,6	34,6	0,0	42,3	34,6	34,6
24	42,3	46,2	0,0	50,0	46,2	46,2
25	38,5	34,6	0,0	50,0	34,6	42,3
26	69,2	65,4	0,0	50,0	65,4	73,1

Continua na próxima página

27	42,3	15,4	0,0	50,0	15,4	38,5
28	34,6	42,3	0,0	50,0	42,3	34,6
29	61,5	26,9	0,0	38,5	26,9	61,5
30	38,5	38,5	0,0	50,0	38,5	38,5
31	50,0	46,2	0,0	46,2	46,2	38,5
32	65,4	57,7	0,0	65,4	57,7	53,8
33	38,5	50,0	0,0	38,5	50,0	46,2
34	42,3	38,5	0,0	46,2	38,5	38,5
35	61,5	19,2	0,0	50,0	19,2	53,8
36	53,8	50,0	0,0	38,5	50,0	53,8
37	42,3	38,5	0,0	50,0	38,5	50,0
38	38,5	19,2	0,0	38,5	19,2	38,5
39	34,6	34,6	0,0	42,3	34,6	38,5
40	38,5	30,8	0,0	38,5	30,8	42,3
41	46,2	61,5	0,0	38,5	61,5	42,3
42	42,3	30,8	0,0	50,0	30,8	30,8
43	65,4	61,5	0,0	76,9	61,5	65,4
44	38,5	30,8	0,0	34,6	38,5	46,2
45	57,7	23,1	0,0	50,0	23,1	61,5
46	38,5	19,2	0,0	46,2	19,2	38,5
47	57,7	46,2	0,0	46,2	46,2	53,8
48	42,3	11,5	0,0	38,5	11,5	42,3
49	46,2	53,8	0,0	50,0	53,8	46,2
50	65,4	50,0	0,0	30,8	50,0	65,4
Valor médio	47,2	38,7	0,0	46,4	38,9	45,9

Tabela G.1.4 Precisão da classificação binária descafeinado/café com PCA=10% usando os classificadores *Ensemble*.

Análise ao minuto	<i>Boosted Tress</i>	<i>Bagged Trees</i>	<i>Subspace Discriminant</i>	<i>Subspace KNN</i>	<i>Rusboosted Trees</i>
1	0,0	46,2	46,2	46,2	15,4
2	0,0	42,3	53,8	46,2	26,9
3	0,0	30,8	46,2	30,8	19,2
4	0,0	50,0	3,8	50,0	38,5
5	0,0	42,3	0,0	38,5	26,9
6	0,0	69,2	53,8	69,2	15,4
7	0,0	38,5	0,0	38,5	23,1
8	0,0	57,7	38,5	57,7	30,8

Continua na próxima página

9	0,0	26,9	3,8	26,9	26,9
10	0,0	53,8	0,0	53,8	11,5
11	0,0	46,2	0,0	42,3	15,4
12	0,0	46,2	34,6	46,2	34,6
13	0,0	34,6	42,3	36,6	11,5
14	0,0	38,5	19,2	38,5	23,1
15	0,0	42,3	0,0	42,3	23,1
16	0,0	38,5	0,0	38,5	26,9
17	0,0	46,2	42,3	50,0	19,2
18	0,0	61,5	0,0	65,4	19,2
19	0,0	50,0	26,9	50,0	30,8
20	0,0	46,2	15,4	46,2	30,8
21	0,0	53,8	19,2	53,8	19,2
22	0,0	69,2	50,0	69,2	38,5
23	0,0	34,6	0,0	34,6	23,1
24	0,0	42,3	0,0	42,3	19,2
25	0,0	38,5	46,2	38,5	23,1
26	0,0	73,1	46,2	69,2	34,6
27	0,0	42,3	0,0	42,3	42,3
28	0,0	34,6	38,5	34,6	15,4
29	0,0	61,5	3,8	61,5	42,3
30	0,0	38,5	0,0	38,5	23,1
31	0,0	46,2	38,5	50,0	30,8
32	0,0	65,4	30,8	65,4	46,2
33	0,0	38,5	0,0	38,5	15,4
34	0,0	42,3	42,3	42,3	3,8
35	0,0	61,5	53,8	61,5	26,9
36	0,0	53,8	0,0	53,8	19,2
37	0,0	38,5	53,8	42,3	26,9
38	0,0	38,5	23,1	38,5	38,5
39	0,0	34,6	0,0	34,6	30,8
40	0,0	38,5	0,0	38,5	11,5
41	0,0	46,2	57,7	46,2	26,9
42	0,0	42,3	50,0	42,3	23,1
43	0,0	65,4	73,1	65,4	34,6
44	0,0	50,0	46,2	53,8	19,2
45	0,0	57,7	57,7	57,7	19,2
46	0,0	42,4	46,2	38,5	26,9
47	0,0	57,7	7,7	57,7	26,9
48	0,0	46,2	0,0	42,3	34,6

49	0,0	46,2	0,0	46,2	42,3
50	0,0	65,4	38,5	65,4	19,2
Valor médio	0,0	47,5	25,0	47,6	25,5

G.2 Classificação Binária OF_placebo/OF_cafeína

Tabela G.2.1 Precisão da classificação binária OF_placebo/OF_cafeína com PCA=10% usando os classificadores de árvore de decisão, análise discriminante, regressão logística e naïve bayes.

Análise ao minuto	<i>Fine Tree</i>	<i>Medium Tree</i>	<i>Coarse Tree</i>	<i>Lineaar Discriminant</i>	<i>Logist Regression</i>	<i>Naïve Bayes Gaussiane</i>
1	80,8	80,8	80,8	65,4	65,4	69,2
2	57,7	57,7	57,7	69,2	69,2	73,1
3	69,2	69,2	69,2	69,2	65,4	69,2
4	73,1	73,1	73,1	61,5	61,5	57,7
5	50,0	50,0	50,0	61,5	61,5	65,4
6	61,5	61,5	57,7	65,4	65,4	69,2
7	69,2	69,2	69,2	53,8	53,8	65,4
8	61,5	61,5	61,5	57,7	57,7	65,4
9	76,9	76,9	76,9	61,5	61,5	65,4
10	61,5	61,5	61,5	76,9	65,4	76,9
11	80,8	80,8	80,8	0,0	0,0	57,7
12	53,8	53,8	53,8	69,2	69,2	65,4
13	53,8	53,8	57,7	53,8	53,8	50,0
14	57,7	57,7	57,7	61,5	61,5	46,2
15	53,8	53,8	57,7	15,4	15,4	50,0
16	53,8	53,8	53,8	57,7	57,7	61,5
17	53,8	53,8	57,7	65,4	57,7	73,1
18	73,1	73,1	73,1	65,4	65,4	65,4
19	73,1	73,1	73,1	61,5	61,5	69,2
20	69,2	69,2	69,2	69,2	65,4	65,4
21	65,4	65,4	65,4	57,7	57,7	73,1
22	69,2	69,2	69,2	69,2	69,2	69,2
23	65,4	65,4	65,4	69,2	69,2	69,2
24	73,1	73,1	73,1	69,2	69,2	76,9
25	57,7	57,7	57,7	61,5	61,5	57,7
26	73,1	73,1	73,1	65,4	65,4	69,2

Continua na próxima página

27	53,8	53,8	53,8	53,8	53,8	50,0
28	73,1	73,1	73,1	65,4	65,4	65,4
29	69,2	69,2	69,2	76,9	76,9	73,1
30	73,1	73,1	73,1	65,4	65,4	65,4
31	73,1	73,1	73,1	65,4	65,4	69,2
32	80,8	80,8	80,8	69,2	69,2	69,2
33	61,5	61,5	61,5	61,5	61,5	73,1
34	61,5	61,5	61,5	69,2	69,2	65,4
35	61,5	61,5	61,5	57,7	57,7	65,4
36	69,2	69,2	69,2	80,8	76,9	76,9
37	69,2	69,2	69,2	46,2	46,2	61,5
38	65,4	65,4	65,4	69,2	69,2	73,1
39	65,4	65,4	65,4	0,0	0,0	42,3
40	76,9	76,9	76,9	65,4	65,4	69,2
41	65,4	65,4	65,4	0,0	0,0	0,0
42	69,2	69,2	69,2	53,8	53,8	57,7
43	76,9	76,9	76,9	57,7	57,7	65,4
44	53,8	53,8	57,7	57,7	57,7	65,4
45	73,1	73,1	73,1	65,4	65,4	73,1
46	76,9	76,9	76,9	57,7	57,7	65,4
47	65,4	65,4	65,4	61,5	69,2	61,5
48	69,2	69,2	69,2	15,4	19,2	30,8
49	69,2	69,2	69,2	69,2	69,2	76,9
50	73,1	73,1	73,1	61,5	61,5	73,1
Valor médio	66,7	66,7	66,9	58,0	57,6	63,7

Tabela G.2.2 Precisão da classificação binária OF_placebo/OF_cafeína com PCA=10% usando os classificadores SVM.

Análise ao minuto	Linear SVM	Quadratic SVM	Cubic SVM	Fine Gaussian SVM	Medium Gaussian SVM	Coarse Gaussian SVM
1	69,2	73,1	73,1	76,9	0,0	0,0
2	73,1	76,9	57,7	73,1	0,0	0,0
3	76,9	69,2	61,5	76,9	0,0	0,0
4	61,5	69,2	30,8	61,5	0,0	0,0
5	65,4	69,2	76,9	65,4	0,0	0,0
6	73,1	73,1	61,5	76,9	0,0	0,0
7	53,8	73,1	69,2	65,4	0,0	0,0
8	65,4	73,1	34,6	65,4	0,0	0,0

Continua na próxima página

9	65,4	76,9	69,2	73,1	0,0	0,0
10	69,2	73,1	61,5	76,9	0,0	0,0
11	0,0	57,7	69,2	26,9	0,0	0,0
12	69,2	73,1	73,1	73,1	0,0	0,0
13	57,7	61,6	30,8	53,8	0,0	0,0
14	53,8	65,4	61,5	57,7	0,0	0,0
15	26,9	57,7	53,8	11,5	0,0	0,0
16	57,7	65,4	65,4	65,4	0,0	0,0
17	73,1	73,1	73,1	73,1	0,0	0,0
18	65,4	73,1	57,7	65,4	0,0	0,0
19	73,1	69,2	80,8	76,9	0,0	0,0
20	65,4	73,1	34,6	69,2	0,0	0,0
21	69,2	73,1	69,2	76,9	0,0	0,0
22	69,2	69,2	57,7	76,9	0,0	0,0
23	73,1	69,2	34,6	73,1	0,0	0,0
24	76,9	73,1	46,2	76,9	0,0	0,0
25	57,7	69,2	69,2	65,4	0,0	0,0
26	73,1	76,9	45,2	73,1	0,0	0,0
27	50,0	61,5	57,7	3,8	0,0	0,0
28	65,4	69,2	65,4	76,9	0,0	0,0
29	76,9	65,4	69,2	76,9	0,0	0,0
30	65,4	69,2	69,2	65,4	0,0	0,0
31	69,2	73,1	73,1	73,1	0,0	0,0
32	69,2	80,8	73,1	73,1	0,0	0,0
33	73,1	73,1	73,1	69,2	0,0	0,0
34	69,2	73,1	61,5	73,1	0,0	0,0
35	73,1	73,1	50,0	76,9	0,0	0,0
36	76,9	76,9	65,4	76,9	0,0	0,0
37	50,0	76,9	30,8	57,7	0,0	0,0
38	73,1	73,1	53,8	69,2	0,0	0,0
39	0,0	42,3	73,1	0,0	0,0	0,0
40	76,9	73,1	73,1	76,9	0,0	0,0
41	0,0	0,0	50,0	0,0	0,0	0,0
42	53,8	73,1	76,9	57,7	0,0	0,0
43	61,5	76,9	80,8	69,2	0,0	0,0
44	61,5	69,2	42,3	65,4	0,0	0,0
45	73,1	69,2	46,2	73,1	0,0	0,0
46	61,5	76,9	69,2	61,5	0,0	0,0
47	57,7	57,7	53,8	53,8	0,0	0,0
48	30,8	46,2	65,4	19,2	0,0	0,0

Continua na próxima página

49	80,8	80,8	73,1	80,8	0,0	0,0
50	73,1	73,1	76,9	76,9	0,0	0,0
Valor médio	61,5	68,6	60,8	63,1	0,0	0,0

Tabela G.2.3 Precisão da classificação binária OF_placebo/OF_cafeína com PCA=10% usando os classificadores KNN.

Análise ao minuto	<i>Fine KNN</i>	<i>Medium KNN</i>	<i>Coarse KNN</i>	<i>Cosine KNN</i>	<i>Cubic KNN</i>	<i>Weighted KNN</i>
1	76,9	76,9	0,0	30,8	76,9	76,9
2	69,2	73,1	0,0	30,8	73,1	69,2
3	65,4	80,8	0,0	30,8	80,8	61,5
4	61,5	65,4	0,0	34,6	65,4	61,5
5	53,8	65,4	0,0	30,8	65,4	53,8
6	69,2	76,9	0,0	30,8	76,9	69,2
7	61,5	57,7	0,0	30,8	57,7	61,5
8	53,8	65,4	0,0	30,8	65,4	53,8
9	69,2	73,1	0,0	38,5	73,1	69,2
10	57,7	65,4	0,0	69,2	65,4	57,7
11	73,1	57,7	0,0	65,4	57,7	76,9
12	69,2	73,1	0,0	73,1	73,1	69,2
13	50,0	65,4	0,0	30,8	65,4	50,0
14	57,7	69,2	0,0	73,1	69,2	57,7
15	65,4	46,2	0,0	34,6	46,2	65,4
16	57,7	65,4	0,0	53,8	65,4	61,5
17	76,9	57,7	0,0	50,0	57,7	69,2
18	57,7	65,4	0,0	42,3	65,4	57,7
19	80,8	65,4	0,0	50,0	65,4	80,8
20	65,4	61,5	0,0	50,0	61,5	69,2
21	73,1	73,1	0,0	30,8	73,1	76,9
22	65,4	73,1	0,0	76,9	73,1	65,4
23	61,5	73,1	0,0	30,8	73,1	61,5
24	76,9	73,1	0,0	73,1	73,1	76,9
25	57,7	69,2	0,0	65,4	69,2	61,5
26	53,8	73,1	0,0	30,8	73,1	50,0
27	61,5	57,7	0,0	61,5	57,7	65,4
28	65,4	76,9	0,0	30,8	76,9	69,2
29	61,5	76,9	0,0	80,8	76,9	65,4
30	69,2	65,4	0,0	50,0	65,4	65,4

Continua na próxima página

31	69,2	73,1	0,0	57,7	73,1	69,2
32	69,2	73,1	0,0	69,2	73,1	73,1
33	69,2	73,1	0,0	69,2	73,1	61,5
34	50,0	73,1	0,0	69,2	73,1	57,7
35	57,7	69,2	0,0	30,8	69,2	69,2
36	57,7	76,9	0,0	80,8	76,9	61,5
37	61,5	69,2	0,0	30,8	69,2	65,4
38	53,8	69,2	0,0	30,8	69,2	53,8
39	57,7	53,8	0,0	69,2	53,8	57,7
40	57,7	69,2	0,0	61,5	69,2	57,7
41	57,7	57,7	0,0	38,5	57,7	57,7
42	73,1	57,7	0,0	50,0	57,7	80,8
43	65,4	76,9	0,0	30,8	76,9	61,5
44	46,2	61,5	0,0	50,0	61,5	46,2
45	61,5	73,1	0,0	50,0	73,1	65,4
46	61,5	65,4	0,0	61,5	65,4	65,4
47	53,8	57,7	0,0	73,1	57,7	61,5
48	65,4	61,5	0,0	38,5	61,5	65,4
49	61,5	80,8	0,0	30,8	80,8	65,4
50	61,5	76,9	0,0	30,8	76,9	65,4
Valor médio	63,0	68,2	0,0	48,7	68,2	64,2

Tabela G.2.4 Precisão da classificação binária OF_placebo/OF_cafeina com PCA=10% usando os classificadores *Ensemble*.

Análise ao minuto	<i>Boosted Tress</i>	<i>Bagged Trees</i>	<i>Subspace Discriminant</i>	<i>Subspace KNN</i>	<i>Rusboosted Trees</i>
1	0,0	76,9	65,4	76,9	15,4
2	0,0	69,2	69,2	69,2	15,4
3	0,0	61,5	69,2	65,4	30,8
4	0,0	61,5	61,5	61,5	15,4
5	0,0	57,7	61,5	53,8	26,9
6	0,0	69,2	65,4	69,2	34,6
7	0,0	61,5	53,8	61,5	15,4
8	0,0	53,8	57,7	53,8	30,8
9	0,0	69,2	61,5	69,2	11,5
10	0,0	57,7	76,9	57,7	34,6
11	0,0	73,1	0,0	73,1	15,4
12	0,0	69,2	69,2	69,2	30,8
Continua na próxima página					

13	0,0	50,0	53,8	50,0	23,1
14	0,0	57,7	61,5	57,7	34,6
15	0,0	65,4	15,4	65,4	46,2
16	0,0	57,7	57,7	57,7	11,5
17	0,0	73,1	65,4	76,9	23,1
18	0,0	57,7	65,4	57,7	15,4
19	0,0	80,8	61,5	80,8	19,2
20	0,0	65,4	65,4	65,4	19,2
21	0,0	73,1	57,7	73,1	23,1
22	0,0	65,4	69,2	65,4	11,5
23	0,0	61,5	69,2	61,5	26,9
24	0,0	76,9	69,2	76,9	19,2
25	0,0	57,7	61,5	57,7	15,4
26	0,0	53,8	65,4	53,8	23,1
27	0,0	57,7	53,8	61,5	15,4
28	0,0	65,4	65,4	65,4	30,8
29	0,0	61,5	76,9	61,5	38,5
30	0,0	69,2	65,4	69,2	26,9
31	0,0	69,2	65,4	69,2	15,4
32	0,0	69,2	69,2	69,2	23,1
33	0,0	69,2	61,5	69,2	30,8
34	0,0	53,8	69,2	50,0	30,8
35	0,0	57,7	57,7	57,7	19,2
36	0,0	57,7	80,8	57,7	23,1
37	0,0	61,5	46,2	61,5	26,9
38	0,0	53,8	69,2	53,8	30,8
39	0,0	57,7	0,0	57,7	30,8
40	0,0	61,5	65,4	57,7	23,1
41	0,0	57,7	0,0	57,7	26,9
42	0,0	73,1	53,8	73,1	19,2
43	0,0	65,4	57,7	65,4	11,5
44	0,0	46,2	57,7	46,2	19,2
45	0,0	65,4	65,4	61,5	34,6
46	0,0	61,5	57,7	61,5	26,9
47	0,0	53,8	61,5	53,8	23,1
48	0,0	65,4	15,4	65,4	26,9
49	0,0	61,5	69,2	61,5	23,1
50	0,0	57,7	61,5	61,5	23,1
Valor médio	0,0	63,0	57,9	63,0	23,8



Precisão dos Classificadores com PCA=5%

H.1 Classificação Binária Descafeinado/Café

Tabela H.1.1 Precisão da classificação binária descafeinado/café com PCA=5% usando os classificadores de árvore de decisão, análise discriminante, regressão logística e *naïve bayes*.

Análise ao minuto	<i>Fine Tree</i>	<i>Medium Tree</i>	<i>Coarse Tree</i>	<i>Lineaar Discriminant</i>	<i>Logist Regression</i>	<i>Naïve Bayes Gaussiane</i>
1	38,5	38,5	38,5	46,2	46,2	50,0
2	23,1	23,1	23,1	53,8	53,8	53,8
3	46,2	46,2	38,5	46,2	46,2	50,0
4	38,5	38,5	42,3	3,8	7,7	3,8
5	38,5	38,5	38,5	0,0	0,0	34,6
6	61,5	61,5	57,7	53,8	57,7	46,2
7	34,6	34,6	34,6	0,0	0,0	19,2
8	38,5	38,5	38,5	38,5	38,5	46,2
9	7,7	7,7	3,8	3,8	7,7	30,8
10	61,5	61,5	61,5	0,0	0,0	7,7
11	46,2	46,2	38,5	0,0	0,0	0,0
12	30,8	30,8	11,5	34,6	34,6	50,0
13	34,6	34,6	42,3	42,3	46,2	38,5
14	46,2	46,2	38,5	19,2	26,9	26,9
15	23,1	23,1	15,4	0,0	0,0	0,0
16	30,8	30,8	19,2	0,0	0,0	0,0
17	42,3	42,3	42,3	38,5	42,3	42,3
18	50,0	50,0	38,5	0,0	0,0	57,7
19	38,5	38,5	34,6	26,9	30,8	23,1
20	65,4	65,4	65,4	15,4	23,1	38,5
21	42,3	42,3	42,3	19,2	23,1	42,3
22	53,8	53,8	53,8	50,0	50,0	46,2

Continua na próxima página

23	30,8	30,8	34,6	0,0	0,0	23,1
24	57,7	57,7	57,7	0,0	0,0	57,7
25	34,6	34,6	34,6	46,2	46,2	53,8
26	50,0	50,0	50,0	46,2	46,2	46,2
27	38,5	38,5	23,1	0,0	0,0	3,8
28	50,0	50,0	53,8	38,5	42,3	46,2
29	61,5	61,5	61,5	3,8	3,8	3,8
30	38,5	38,5	38,5	0,0	0,0	38,5
31	50,0	50,0	50,0	38,5	38,5	50,0
32	53,8	53,8	53,8	30,8	34,6	50,0
33	42,3	42,3	42,3	0,0	0,0	0,0
34	50,0	50,0	50,0	42,3	42,3	46,2
35	46,2	46,2	50,0	53,8	53,8	46,2
36	53,8	53,8	53,8	0,0	0,0	26,9
37	53,8	53,8	42,3	53,8	53,8	53,8
38	38,5	38,5	30,8	23,1	23,1	46,2
39	57,7	57,7	57,7	0,0	3,8	38,5
40	26,9	26,9	34,6	0,0	0,0	57,7
41	50,0	50,0	50,0	57,7	57,7	57,7
42	30,8	30,8	34,6	50,0	50,0	30,8
43	73,1	73,1	76,9	73,1	73,1	57,7
44	46,2	46,2	46,2	42,3	46,2	50,0
45	53,8	53,8	53,8	57,7	57,7	53,8
46	42,3	42,3	26,9	46,2	46,2	34,6
47	50,0	50,0	50,0	7,7	7,7	26,9
48	42,3	42,3	42,3	0,0	0,0	23,1
49	46,2	46,2	46,2	0,0	0,0	50,0
50	69,2	69,2	69,2	38,5	38,5	53,8
Valor médio	44,6	44,6	42,7	24,8	26,0	36,7

Tabela H.1.2 Precisão da classificação binária descafeinado/café com PCA=5% usando os classificadores SVM.

Análise ao minuto	<i>Linear SVM</i>	<i>Quadratic SVM</i>	<i>Cubic SVM</i>	<i>Fine Gaussian SVM</i>	<i>Medium Gaussian SVM</i>	<i>Coarse Gaussian SVM</i>
1	53,8	38,5	42,3	7,7	0,0	0,0
2	50,0	46,2	42,3	42,3	0,0	0,0
3	46,2	34,6	46,2	42,3	0,0	0,0
4	3,8	7,7	50,0	0,0	0,0	0,0

Continua na próxima página

5	0,0	46,2	53,8	0,0	0,0	0,0
6	50,0	57,7	57,7	46,2	0,0	0,0
7	0,0	7,7	34,6	0,0	0,0	0,0
8	42,3	23,1	34,6	0,0	0,0	0,0
9	0,0	30,8	38,5	0,0	0,0	0,0
10	0,0	46,2	38,5	0,0	0,0	0,0
11	0,0	0,0	53,8	0,0	0,0	0,0
12	11,4	53,8	0,0	0,0	0,0	46,2
13	46,2	19,2	38,5	0,0	0,0	0,0
14	11,5	42,3	26,9	0,0	0,0	0,0
15	0,0	0,0	30,8	0,0	0,0	0,0
16	0,0	0,0	42,3	0,0	0,0	0,0
17	42,3	38,5	46,2	0,0	0,0	0,0
18	0,0	61,5	26,9	0,0	0,0	0,0
19	7,7	26,9	46,2	0,0	0,0	0,0
20	3,8	46,2	42,3	0,0	0,0	0,0
21	42,3	46,2	38,5	0,0	0,0	0,0
22	46,2	42,3	30,8	0,0	0,0	0,0
23	0,0	38,5	46,2	0,0	0,0	0,0
24	0,0	61,5	61,5	0,0	0,0	0,0
25	53,8	50,0	26,9	0,0	0,0	0,0
26	36,2	38,5	46,2	34,6	0,0	0,0
27	0,0	0,0	30,8	0,0	0,0	0,0
28	46,2	50,0	34,6	0,0	0,0	0,0
29	3,8	3,8	42,3	0,0	0,0	0,0
30	0,0	50,0	38,5	0,0	0,0	0,0
31	38,5	42,3	61,5	3,8	0,0	0,0
32	53,8	65,4	57,7	38,5	0,0	0,0
33	0,0	11,5	50,0	0,0	0,0	0,0
34	19,2	53,8	46,2	3,8	0,0	0,0
35	53,8	42,3	57,7	30,8	0,0	0,0
36	0,0	42,3	46,2	0,0	0,0	0,0
37	57,7	53,8	30,8	50,0	0,0	0,0
38	0,0	38,5	50,0	0,0	0,0	0,0
39	0,0	38,5	23,1	0,0	0,0	0,0
40	0,0	61,5	23,1	0,0	0,0	0,0
41	61,5	53,8	61,5	61,5	0,0	0,0
42	34,6	50,0	42,3	0,0	0,0	0,0
43	76,9	53,8	53,8	57,7	0,0	0,0
44	42,3	46,2	46,2	38,5	0,0	0,0

Continua na próxima página

45	53,8	38,5	46,2	46,2	0,0	0,0
46	38,5	11,5	50,0	15,4	0,0	0,0
47	0,0	38,5	30,8	0,0	0,0	0,0
48	0,0	42,3	50,0	0,0	0,0	0,0
49	0,0	57,7	53,8	0,0	0,0	0,0
50	38,5	61,5	53,8	3,8	0,0	0,0
Valor médio	23,3	38,2	42,5	10,5	0,0	0,9

Tabela H.1.3 Precisão da classificação binária descafeinado/café com PCA=5% usando os classificadores KNN.

Análise ao minuto	<i>Fine KNN</i>	<i>Medium KNN</i>	<i>Coarse KNN</i>	<i>Cosine KNN</i>	<i>Cubic KNN</i>	<i>Weighted KNN</i>
1	46,2	42,3	0,0	50,0	42,3	38,5
2	46,2	38,5	0,0	50,0	38,5	46,2
3	30,8	57,7	0,0	42,3	57,7	34,6
4	50,0	38,5	0,0	50,0	38,5	50,0
5	38,5	50,0	0,0	50,0	50,0	38,5
6	69,2	57,7	0,0	42,3	57,7	65,4
7	38,5	34,6	0,0	50,0	34,6	38,5
8	57,7	34,6	0,0	50,0	34,6	50,0
9	26,9	30,8	0,0	42,3	30,8	30,8
10	53,8	34,6	0,0	50,0	34,6	43,8
11	42,3	19,2	0,0	38,5	19,2	42,3
12	46,2	30,8	0,0	50,0	30,8	38,5
13	34,6	38,5	0,0	50,0	38,5	34,6
14	38,5	19,2	0,0	34,6	19,2	38,5
15	42,3	30,8	0,0	42,3	30,8	26,9
16	38,5	38,5	0,0	50,0	38,5	26,9
17	50,0	34,6	0,0	42,3	34,6	53,8
18	65,4	46,2	0,0	50,0	46,2	57,7
19	50,0	34,6	0,0	46,2	34,6	46,2
20	46,2	42,3	0,0	42,3	42,3	42,3
21	53,8	61,5	0,0	50,0	61,5	53,8
22	69,2	42,3	0,0	50,0	42,3	69,2
23	34,6	34,6	0,0	42,3	34,6	34,6
24	42,3	46,2	0,0	50,0	46,2	46,2
25	38,5	34,6	0,0	50,0	34,6	42,3
26	69,2	65,4	0,0	50,0	65,4	73,1

Continua na próxima página

27	42,3	15,4	0,0	50,0	15,4	38,5
28	34,6	42,3	0,0	50,0	42,3	34,6
29	61,5	26,9	0,0	38,5	36,9	61,5
30	38,5	38,5	0,0	50,0	38,5	38,5
31	50,0	46,2	0,0	46,2	46,2	38,5
32	65,4	57,7	0,0	65,4	57,7	53,8
33	38,5	50,0	0,0	38,5	50,0	46,2
34	42,3	38,5	0,0	46,2	38,5	38,5
35	61,5	19,2	0,0	50,0	19,2	53,8
36	53,8	50,0	0,0	38,5	50,0	53,8
37	42,3	38,5	0,0	50,0	38,5	50,0
38	38,5	19,2	0,0	38,5	19,2	38,5
39	34,6	34,6	0,0	42,3	34,6	38,5
40	38,5	30,8	0,0	38,5	30,8	42,3
41	46,2	61,5	0,0	38,5	61,5	42,3
42	42,3	30,8	0,0	50,0	30,8	30,8
43	65,4	61,5	0,0	76,9	61,5	65,4
44	38,5	61,5	0,0	42,3	0,0	61,5
45	57,7	23,1	0,0	50,0	23,1	61,5
46	38,5	19,2	0,0	46,2	19,2	38,5
47	57,7	46,2	0,0	46,2	46,2	53,8
48	42,3	11,5	0,0	38,5	11,5	42,3
49	46,2	53,8	0,0	50,0	53,8	46,2
50	65,4	50,0	0,0	30,8	50,0	65,4
Valor médio	47,2	39,3	0,0	46,5	38,3	46,0

Tabela H.1.4 Precisão da classificação binária descafeinado/café com PCA=5% usando os classificadores *Ensemble*.

Análise ao minuto	<i>Boosted Tress</i>	<i>Bagged Trees</i>	<i>Subspace Discriminant</i>	<i>Subspace KNN</i>	<i>Rusboosted Trees</i>
1	0,0	46,2	46,2	46,2	30,8
2	0,0	42,3	53,8	46,2	30,8
3	0,0	30,8	46,2	30,8	34,6
4	0,0	50,0	3,8	50,0	38,5
5	0,0	38,5	0,0	38,5	23,1
6	0,0	69,2	53,9	69,2	34,6
7	0,0	38,5	0,0	38,5	34,6
8	0,0	53,8	38,5	57,7	34,6

Continua na próxima página

9	0,0	26,9	3,8	26,9	19,2
10	0,0	50,0	0,0	53,8	34,6
11	0,0	42,3	0,0	42,3	15,4
12	0,0	46,2	34,6	46,2	38,5
13	0,0	34,6	42,3	34,6	15,4
14	0,0	38,5	19,2	38,5	23,1
15	0,0	42,3	0,0	42,3	30,8
16	0,0	38,5	0,0	38,5	23,1
17	0,0	46,2	42,3	50,0	19,2
18	0,0	65,4	0,0	65,4	15,4
19	0,0	50,0	26,9	50,0	30,8
20	0,0	46,2	15,4	46,2	38,5
21	0,0	53,8	19,2	53,8	30,8
22	0,0	69,2	50,0	69,2	30,8
23	0,0	34,6	0,0	34,6	15,2
24	0,0	42,3	0,0	42,3	11,5
25	0,0	38,5	46,2	38,5	30,8
26	0,0	69,2	46,2	69,2	23,1
27	0,0	42,3	0,0	42,3	30,8
28	0,0	30,8	38,5	34,6	23,1
29	0,0	61,5	3,8	61,5	34,6
30	0,0	38,5	0,0	38,5	15,4
31	0,0	50,0	38,5	50,0	19,2
32	0,0	65,4	30,8	65,4	26,9
33	0,0	38,5	0,0	38,5	19,2
34	0,0	46,2	42,3	42,3	19,2
35	0,0	61,5	53,8	61,5	30,8
36	0,0	53,8	0,0	53,8	19,2
37	0,0	42,3	53,8	42,3	26,9
38	0,0	38,5	23,1	38,5	11,5
39	0,0	34,6	0,0	34,6	19,2
40	0,0	38,5	57,7	34,6	11,5
41	0,0	46,2	57,7	46,2	26,9
42	0,0	42,3	50,0	42,3	19,2
43	0,0	65,4	73,1	65,4	23,1
44	0,0	38,5	42,3	38,5	23,1
45	0,0	53,8	57,7	57,7	26,9
46	0,0	38,5	46,2	38,5	11,5
47	0,0	53,8	7,7	57,7	15,4
48	0,0	42,3	0,0	42,3	23,1

Continua na próxima página

49	0,0	46,2	0,0	46,2	34,6
50	0,0	65,4	38,5	65,4	15,4
Valor médio	0,0	46,8	26,1	47,2	24,7

H.2 Classificação Binária OF_placebo/OF_cafeína

Tabela H.2.1 Precisão da classificação binária OF_placebo/OF_cafeína com PCA=5% usando os classificadores de árvore de decisão, análise discriminante, regressão logística e *naïve bayes*.

Análise ao minuto	<i>Fine Tree</i>	<i>Medium Tree</i>	<i>Coarse Tree</i>	<i>Lineaar Discriminant</i>	<i>Logist Regression</i>	<i>Naïve Bayes Gaussiane</i>
1	80,8	80,8	80,8	65,4	65,4	69,2
2	57,7	57,7	57,7	69,2	69,2	73,1
3	69,2	69,2	69,2	69,2	65,4	69,2
4	73,1	73,1	73,1	61,5	61,5	57,7
5	50,0	50,0	50,0	61,5	61,5	65,4
6	61,5	61,5	57,7	65,4	65,4	69,2
7	69,2	69,2	69,2	53,8	53,8	65,4
8	61,5	61,5	61,5	57,7	57,7	65,4
9	76,9	76,9	76,9	61,5	61,5	65,4
10	61,5	61,5	61,5	76,9	65,4	76,9
11	80,8	80,8	80,8	0,0	0,0	57,7
12	53,8	53,8	53,8	69,2	69,2	65,4
13	53,8	53,8	57,7	53,8	53,8	50,0
14	57,7	57,7	57,7	61,5	61,5	46,2
15	53,8	53,8	57,7	15,4	15,4	50,0
16	53,8	53,8	53,8	57,7	57,7	61,5
17	53,8	53,8	57,7	65,4	57,7	73,1
18	73,1	73,1	73,1	65,4	65,4	65,4
19	73,1	73,1	73,1	61,5	61,5	69,2
20	69,2	69,2	69,2	65,4	65,4	65,4
21	65,4	65,4	65,4	57,7	57,7	73,1
22	69,2	69,2	69,2	69,2	69,2	69,2
23	65,4	65,4	65,4	69,2	69,2	69,2
24	73,1	73,1	73,1	69,2	69,2	76,9
25	57,7	57,7	57,7	61,5	61,5	57,7
26	73,1	73,1	73,1	65,4	65,4	69,2
27	53,8	53,8	53,8	53,8	53,8	50,0

Continua na próxima página

28	73,1	73,1	73,1	65,4	65,4	65,4
29	69,2	69,2	69,2	76,9	76,9	73,1
30	73,1	73,1	73,1	65,4	65,4	65,4
31	73,1	73,1	73,1	65,4	65,4	69,2
32	80,8	80,8	80,8	69,2	69,2	69,2
33	61,5	61,5	61,5	61,5	61,5	73,1
34	61,5	61,5	61,5	69,2	69,2	65,4
35	61,5	61,5	61,5	57,7	57,7	65,4
36	69,2	69,2	69,2	80,8	76,9	76,9
37	69,2	69,2	69,2	46,2	46,2	61,5
38	65,4	65,4	65,4	69,2	69,2	73,1
39	65,4	65,4	65,4	0,0	0,0	42,3
40	76,9	76,9	76,9	65,4	65,4	69,2
41	50,0	50,0	50,0	57,7	57,7	57,7
42	69,2	69,2	69,2	53,8	53,8	57,7
43	76,9	76,9	76,9	57,7	57,7	65,4
44	53,8	53,8	57,7	57,7	57,7	65,4
45	73,1	73,1	73,1	65,4	65,4	73,1
46	76,9	76,9	76,9	57,7	57,7	65,4
47	65,4	65,4	65,4	61,5	69,2	61,5
48	69,2	69,2	69,2	15,4	19,2	30,8
49	69,2	69,2	69,2	69,2	69,2	76,9
50	73,1	73,1	73,1	61,5	61,5	73,1
Valor médio	66,4	66,4	66,6	59,1	58,8	64,8

Tabela H.2.2 Precisão da classificação binária OF_placebo/OF_cafeína com PCA=5% usando os classificadores SVM.

Análise ao minuto	<i>Linear SVM</i>	<i>Quadratic SVM</i>	<i>Cubic SVM</i>	<i>Fine Gaussian SVM</i>	<i>Medium Gaussian SVM</i>	<i>Coarse Gaussian SVM</i>
1	69,2	73,1	73,1	76,9	0,0	0,0
2	73,1	76,9	57,7	73,1	0,0	0,0
3	76,9	69,2	61,5	76,9	0,0	0,0
4	61,5	69,2	30,8	61,5	0,0	0,0
5	65,4	69,2	76,9	65,4	0,0	0,0
6	73,1	73,1	61,5	76,9	0,0	0,0
7	53,8	73,1	69,2	65,4	0,0	0,0
8	65,4	73,1	34,8	65,4	0,0	0,0
9	65,4	76,9	69,2	73,1	0,0	0,0

Continua na próxima página

10	69,2	73,1	61,5	76,9	0,0	0,0
11	0,0	57,7	69,2	26,9	0,0	0,0
12	69,2	73,1	73,1	73,1	0,0	0,0
13	57,7	61,5	30,8	53,8	0,0	0,0
14	53,8	65,4	61,5	57,7	0,0	0,0
15	26,9	57,7	53,8	11,5	0,0	0,0
16	57,7	65,4	65,4	65,4	0,0	0,0
17	73,1	73,1	73,1	73,1	0,0	0,0
18	65,4	73,1	57,7	65,4	0,0	0,0
19	73,1	69,2	80,8	76,9	0,0	0,0
20	73,1	73,1	34,6	69,2	0,0	0,0
21	69,2	73,1	69,2	76,9	0,0	0,0
22	69,2	69,2	57,7	76,9	0,0	0,0
23	73,1	69,2	34,6	73,1	0,0	0,0
24	76,9	73,1	46,2	76,9	0,0	0,0
25	57,7	69,2	69,2	65,4	0,0	0,0
26	73,1	76,9	46,2	73,1	0,0	0,0
27	50,0	61,5	57,7	3,8	0,0	0,0
28	65,4	69,2	65,4	76,9	0,0	0,0
29	76,9	65,4	69,2	76,9	0,0	0,0
30	65,4	69,2	69,2	65,4	0,0	0,0
31	69,2	73,1	73,1	73,1	0,0	0,0
32	69,2	80,8	73,1	73,1	0,0	0,0
33	73,1	73,1	73,1	69,2	0,0	0,0
34	69,2	73,1	61,5	73,1	0,0	0,0
35	73,1	73,1	50,0	76,9	0,0	0,0
36	76,9	76,9	65,4	76,9	0,0	0,0
37	50,0	76,9	30,8	57,7	0,0	0,0
38	73,1	73,1	53,8	69,2	0,0	0,0
39	0,0	42,3	73,1	0,0	0,0	0,0
40	76,9	73,1	73,1	76,9	0,0	0,0
41	61,5	53,8	61,5	61,5	0,0	0,0
42	53,8	73,1	76,9	57,7	0,0	0,0
43	61,5	76,9	80,8	69,2	0,0	0,0
44	61,5	69,2	42,3	65,4	0,0	0,0
45	73,1	69,2	46,2	73,1	0,0	0,0
46	61,5	76,9	69,2	61,5	0,0	0,0
47	57,7	57,7	53,8	53,8	0,0	0,0
48	30,8	46,2	65,4	19,2	0,0	0,0
Continua na próxima página						

49	80,8	80,8	73,1	80,8	0,0	0,0
50	73,1	73,1	76,9	76,9	0,0	0,0
Valor médio	62,9	69,7	61,1	64,3	0,0	0,0

Tabela H.2.3 Precisão da classificação binária OF_placebo/OF_cafeína com PCA=5% usando os classificadores KNN.

Análise ao minuto	<i>Fine KNN</i>	<i>Medium KNN</i>	<i>Coarse KNN</i>	<i>Cosine KNN</i>	<i>Cubic KNN</i>	<i>Weighted KNN</i>
1	76,9	76,9	0,0	30,8	76,9	76,9
2	69,2	73,1	0,0	30,8	73,1	69,2
3	65,4	80,8	0,0	30,8	80,8	61,5
4	61,5	65,4	0,0	34,6	65,4	61,5
5	53,8	65,4	0,0	30,8	65,4	53,8
6	69,2	76,9	0,0	30,8	76,9	69,2
7	61,5	57,7	0,0	30,8	57,7	61,5
8	53,8	65,4	0,0	30,8	65,4	53,8
9	69,2	73,1	0,0	38,5	73,1	69,2
10	57,7	65,4	0,0	69,2	65,4	57,7
11	73,1	57,7	0,0	65,4	57,7	76,9
12	69,2	73,1	0,0	73,1	73,1	69,2
13	50,0	65,4	0,0	30,8	65,4	50,0
14	57,7	69,2	0,0	73,1	69,2	57,7
15	65,4	46,2	0,0	34,6	46,2	65,4
16	57,7	65,4	0,0	53,8	65,4	61,5
17	76,9	57,7	0,0	50,0	57,7	69,2
18	57,7	65,4	0,0	42,3	65,4	69,3
19	80,8	65,4	0,0	50,0	65,4	80,8
20	65,4	61,5	0,0	50,0	61,5	69,2
21	73,1	73,1	0,0	30,8	73,1	76,9
22	65,4	73,1	0,0	76,9	73,1	65,4
23	61,5	73,1	0,0	30,8	73,1	61,5
24	76,9	73,1	0,0	73,1	73,1	76,9
25	57,7	69,2	0,0	65,4	69,2	61,5
26	53,8	73,1	0,0	30,8	73,1	50,0
27	61,5	57,7	0,0	61,5	57,7	65,4
28	65,4	76,9	0,0	30,8	76,9	69,2
29	61,5	76,9	0,0	80,8	76,9	65,4
30	69,2	65,4	0,0	50,0	65,4	65,4

Continua na próxima página


31	69,2	73,1	0,0	57,7	73,1	69,2
32	69,2	73,1	0,0	69,2	73,1	73,1
33	69,2	73,1	0,0	69,2	73,1	61,5
34	50,0	73,1	0,0	69,2	73,1	57,7
35	57,7	69,2	0,0	30,8	69,2	69,2
36	57,7	76,9	0,0	80,8	76,9	61,5
37	61,5	69,2	0,0	30,8	69,2	65,4
38	53,8	69,2	0,0	30,8	69,2	53,8
39	57,7	53,8	0,0	69,2	53,8	57,7
40	57,7	69,2	0,0	61,5	69,2	57,7
41	46,2	61,5	0,0	38,5	61,5	42,3
42	73,1	57,7	0,0	50,0	57,7	80,8
43	65,4	76,9	0,0	30,8	76,9	61,5
44	46,2	61,5	0,0	50,0	61,5	46,2
45	61,5	73,1	0,0	50,0	73,1	65,3
46	61,5	65,4	0,0	61,5	65,4	65,4
47	53,8	57,7	0,0	73,1	57,7	61,5
48	65,4	61,5	0,0	38,5	61,5	65,4
49	61,5	80,8	0,0	30,8	80,8	65,4
50	61,5	76,9	0,0	30,8	76,9	65,4
Valor médio	62,8	68,2	0,0	48,7	68,2	64,1

Tabela H.2.4 Precisão da classificação binária OF_placebo/OF_cafeína com PCA=5% usando os classificadores *Ensemble*.

Análise ao minuto	<i>Boosted Tress</i>	<i>Bagged Trees</i>	<i>Subspace Discriminant</i>	<i>Subspace KNN</i>	<i>Rusboosted Trees</i>
1	0,0	76,9	65,4	76,9	15,4
2	0,0	65,4	69,2	69,2	30,8
3	0,0	65,4	69,2	65,4	7,7
4	0,0	61,5	61,5	61,5	15,4
5	0,0	53,8	61,5	53,8	38,5
6	0,0	69,2	65,4	69,2	46,2
7	0,0	61,5	53,8	61,5	19,2
8	0,0	53,8	57,7	53,8	23,1
9	0,0	69,2	61,5	69,2	15,4
10	0,0	57,7	76,9	57,7	15,4
11	0,0	73,1	0,0	73,1	26,9
12	0,0	61,5	69,2	69,2	19,2

Continua na próxima página

13	0,0	50,0	53,8	50,0	26,9
14	0,0	57,7	61,5	57,7	15,4
15	0,0	69,2	15,4	65,4	19,2
16	0,0	53,8	57,7	57,7	23,1
17	0,0	76,9	65,4	76,9	19,2
18	0,0	57,7	65,4	57,7	11,5
19	0,0	80,8	61,5	80,8	19,2
20	0,0	65,4	65,4	65,4	26,9
21	0,0	73,1	57,7	73,1	26,9
22	0,0	65,4	69,2	65,4	7,7
23	0,0	57,7	69,2	61,5	26,9
24	0,0	76,9	69,2	76,9	30,8
25	0,0	57,7	61,5	57,7	23,1
26	0,0	53,8	65,4	53,9	26,9
27	0,0	61,5	53,8	61,5	23,1
28	0,0	65,4	65,4	65,4	34,6
29	0,0	61,5	76,9	61,5	19,2
30	0,0	65,4	65,4	69,2	34,6
31	0,0	69,2	65,4	69,2	26,9
32	0,0	69,2	69,2	60,2	15,4
33	0,0	69,2	61,5	69,2	15,4
34	0,0	50,0	69,2	50,0	38,5
35	0,0	53,8	57,7	57,7	15,4
36	0,0	61,5	80,8	57,7	23,1
37	0,0	61,5	46,2	61,5	42,3
38	0,0	53,8	69,2	53,8	19,2
39	0,0	57,7	0,0	57,7	23,1
40	0,0	57,7	65,4	57,7	19,2
41	0,0	46,2	57,7	46,2	23,1
42	0,0	73,1	53,8	73,1	30,8
43	0,0	65,4	57,7	65,4	30,8
44	0,0	42,3	57,7	46,2	19,2
45	0,0	61,5	65,4	61,5	42,3
46	0,0	61,5	57,7	61,5	23,1
47	0,0	53,8	61,5	53,8	15,4
48	0,0	65,4	15,4	65,4	15,4
49	0,0	61,5	69,2	61,5	26,9
50	0,0	61,5	61,5	61,5	11,5
Valor médio	0,0	62,3	59,1	62,6	23,3



Precisão dos Classificadores com PCA=1%

I.1 Classificação Binária Descafeinado/Café

Tabela I.1.1 Precisão da classificação binária descafeinado/café com PCA=1% usando os classificadores de árvore de decisão, análise discriminante, regressão logística e *naïve bayes*.

Análise ao minuto	<i>Fine Tree</i>	<i>Medium Tree</i>	<i>Coarse Tree</i>	<i>Lineaar Discriminant</i>	<i>Logist Regression</i>	<i>Naïve Bayes Gaussiane</i>
1	38,5	38,5	38,5	46,2	46,2	50,0
2	23,1	23,1	23,1	53,8	53,8	53,8
3	46,2	46,2	38,5	46,2	46,2	50,0
4	38,5	38,5	42,3	3,8	7,7	3,8
5	38,5	38,5	38,5	0,0	0,0	34,6
6	61,5	61,5	57,7	53,8	57,7	46,2
7	34,6	34,6	34,6	0,0	0,0	19,2
8	38,5	38,5	38,5	38,5	38,5	46,2
9	7,7	7,7	3,8	3,8	7,7	30,8
10	61,5	61,5	61,5	0,0	0,0	7,7
11	46,2	46,2	38,5	0,0	0,0	0,0
12	30,8	30,8	11,5	34,6	34,6	50,0
13	34,6	34,6	42,3	42,3	46,2	38,5
14	46,2	46,2	38,5	19,2	26,9	26,9
15	23,1	23,1	15,4	0,0	0,0	0,0
16	30,8	30,8	19,2	0,0	0,0	0,0
17	42,3	42,3	38,5	42,3	42,3	42,3
18	50,0	50,0	38,5	0,0	0,0	57,7
19	38,5	38,5	34,6	26,9	30,8	23,1
20	65,4	65,4	65,4	15,4	23,1	38,5
21	42,3	42,3	42,3	19,2	23,1	42,3
22	53,8	53,8	53,8	50,0	50,0	46,2

Continua na próxima página

23	30,8	30,8	34,6	0,0	0,0	23,1
24	57,7	57,7	57,7	0,0	0,0	57,7
25	34,6	34,6	34,6	46,2	46,2	53,8
26	50,0	50,0	50,0	46,2	46,2	46,2
27	38,5	38,5	23,1	0,0	0,0	3,8
28	50,0	50,0	53,8	46,2	46,2	38,5
29	61,5	61,5	61,5	3,8	3,8	3,8
30	38,5	38,5	38,5	0,0	0,0	38,5
31	50,0	50,0	50,0	38,5	38,5	50,0
32	53,8	53,8	53,8	30,8	34,6	50,0
33	42,3	42,3	42,3	0,0	0,0	0,0
34	50,0	50,0	50,0	42,3	42,3	46,2
35	46,2	46,2	50,0	53,8	53,8	46,2
36	53,8	53,8	53,8	0,0	0,0	26,9
37	53,8	53,8	42,3	53,8	53,8	53,8
38	38,5	38,5	30,8	23,1	23,1	46,2
39	57,7	57,7	57,7	0,0	3,8	38,5
40	26,9	26,9	34,6	0,0	0,0	57,7
41	50,0	50,0	50,0	57,7	57,7	57,7
42	30,8	30,8	34,6	50,0	50,0	30,8
43	73,1	73,1	76,9	73,1	73,1	57,7
44	46,2	46,2	46,2	42,3	46,2	50,0
45	53,8	53,8	53,8	57,7	57,7	53,8
46	42,3	42,3	26,9	46,2	46,2	34,6
47	50,0	50,0	50,0	7,7	7,7	26,9
48	42,3	42,3	42,3	0,0	0,0	23,1
49	46,2	46,2	46,2	0,0	0,0	50,0
50	69,2	69,2	69,2	38,5	38,5	53,8
Valor médio	44,6	44,6	42,6	25,1	26,1	36,5

Tabela I.1.2 Precisão da classificação binária descafeinado/café com PCA=1% usando os classificadores SVM.

Análise ao minuto	<i>Linear SVM</i>	<i>Quadratic SVM</i>	<i>Cubic SVM</i>	<i>Fine Gaussian SVM</i>	<i>Medium Gaussian SVM</i>	<i>Coarse Gaussian SVM</i>
1	53,8	38,5	42,3	7,7	0,0	0,0
2	50,0	46,2	42,3	42,3	0,0	0,0
3	46,2	34,6	46,2	42,2	0,0	0,0
4	2,8	7,7	50,0	0,0	0,0	0,0

Continua na próxima página

5	0,0	46,2	53,8	0,0	0,0	0,0
6	50,0	57,7	57,7	46,2	0,0	0,0
7	0,0	7,7	34,6	0,0	0,0	0,0
8	42,3	23,1	34,6	0,0	0,0	0,0
9	0,0	30,8	38,5	0,0	0,0	0,0
10	0,0	46,2	38,5	0,0	0,0	0,0
11	0,0	0,0	53,8	0,0	0,0	0,0
12	42,3	11,5	53,8	0,0	0,0	0,0
13	46,2	19,2	38,5	0,0	0,0	0,0
14	11,5	42,3	26,9	0,0	0,0	0,0
15	0,0	0,0	53,8	0,0	0,0	0,0
16	0,0	0,0	46,2	0,0	0,0	0,0
17	42,3	38,5	46,2	0,0	0,0	0,0
18	0,0	61,5	26,9	0,0	0,0	0,0
19	7,7	26,9	46,2	0,0	0,0	0,0
20	3,8	46,2	42,3	0,0	0,0	0,0
21	42,3	46,2	38,5	0,0	0,0	0,0
22	46,2	42,3	30,8	0,0	0,0	0,0
23	0,0	38,5	46,2	0,0	0,0	0,0
24	0,0	61,5	61,5	0,0	0,0	0,0
25	53,8	50,0	26,9	0,0	0,0	0,0
26	38,5	38,5	34,6	0,0	0,0	69,2
27	0,0	0,0	39,8	0,0	0,0	0,0
28	50,0	38,5	0,0	0,0	0,0	34,6
29	3,8	3,8	42,3	0,0	0,0	0,0
30	0,0	50,0	38,5	0,0	0,0	0,0
31	38,5	42,3	38,5	3,8	0,0	0,0
32	53,8	65,4	57,7	38,5	0,0	0,0
33	0,0	11,5	50,0	0,0	0,0	0,0
34	19,2	53,8	46,2	3,8	0,0	0,0
35	53,8	42,3	57,7	30,8	0,0	0,0
36	0,0	42,3	46,2	0,0	0,0	0,0
37	57,7	53,8	30,8	0,0	0,0	0,0
38	0,0	38,5	50,0	0,0	0,0	0,0
39	0,0	38,5	23,1	0,0	0,0	0,0
40	0,0	61,5	23,1	0,0	0,0	0,0
41	61,5	53,8	61,5	61,5	0,0	0,0
42	34,6	50,0	42,3	0,0	0,0	0,0
43	76,9	53,8	53,8	57,7	0,0	0,0
44	42,3	46,2	46,2	38,5	0,0	0,0

Continua na próxima página

45	53,8	38,5	46,2	46,2	0,0	0,0
46	38,5	11,5	50,0	15,4	0,0	0,0
47	0,0	38,5	30,8	0,0	0,0	0,0
48	0,0	42,3	50,0	0,0	0,0	0,0
49	0,0	57,7	53,8	0,0	0,0	0,0
50	38,5	61,5	53,8	3,8	0,0	0,0
Valor médio	24,1	37,2	42,9	8,8	0,0	2,1

Tabela I.1.3 Precisão da classificação binária descafeinado/café com PCA=1% usando os classificadores KNN.

Análise ao minuto	<i>Fine KNN</i>	<i>Medium KNN</i>	<i>Coarse KNN</i>	<i>Cosine KNN</i>	<i>Cubic KNN</i>	<i>Weighted KNN</i>
1	46,2	42,3	0,0	50,0	42,3	38,5
2	46,2	38,5	0,0	50,0	38,5	46,2
3	30,8	57,7	0,0	42,3	57,7	34,6
4	50,0	38,5	0,0	50,0	38,5	50,0
5	38,5	50,0	0,0	50,0	50,0	38,5
6	69,2	57,7	0,0	42,3	57,7	65,4
7	38,5	34,6	0,0	50,0	34,6	38,5
8	57,7	34,6	0,0	50,0	34,6	50,0
9	26,9	30,8	0,0	42,3	30,8	30,8
10	53,8	34,6	0,0	50,0	34,6	53,8
11	42,3	19,2	0,0	38,5	19,2	42,3
12	46,2	30,8	0,0	50,0	30,8	38,5
13	34,6	38,5	0,0	50,0	38,5	34,6
14	38,5	19,2	0,0	34,6	19,2	38,5
15	42,3	30,8	0,0	42,3	30,8	26,9
16	38,5	38,5	0,0	50,0	38,5	26,9
17	50,0	34,6	0,0	42,3	34,6	53,8
18	65,4	46,2	0,0	50,0	46,2	57,7
19	50,0	34,6	0,0	46,3	34,6	46,2
20	46,2	42,3	0,0	42,3	42,3	42,3
21	53,8	61,5	0,0	50,0	61,5	53,8
22	69,2	42,3	0,0	50,0	42,3	69,2
23	34,6	34,6	0,0	42,3	34,6	34,6
24	42,3	46,2	0,0	50,0	46,2	46,2
25	38,5	34,6	0,0	50,0	34,6	42,3
26	69,2	65,4	0,0	50,0	65,4	73,1

Continua na próxima página

27	42,3	15,4	0,0	50,0	15,4	38,5
28	34,6	42,3	0,0	50,0	42,3	34,6
29	61,5	26,9	0,0	38,5	26,9	61,5
30	38,5	38,5	0,0	50,0	38,5	38,5
31	50,0	46,2	0,0	46,2	46,2	38,5
32	65,4	57,7	0,0	65,4	57,7	53,8
33	38,5	50,0	0,0	38,5	50,0	46,2
34	42,3	38,5	0,0	46,2	38,5	38,5
35	61,5	19,2	0,0	50,0	19,2	53,8
36	53,8	50,0	0,0	38,5	50,0	53,8
37	42,3	38,5	0,0	50,0	38,5	50,0
38	38,5	19,2	0,0	38,5	19,2	38,5
39	34,6	34,6	0,0	42,3	34,6	38,5
40	38,5	30,8	0,0	38,5	30,8	42,3
41	46,2	61,5	0,0	38,5	61,5	42,3
42	42,3	30,8	0,0	50,0	30,8	30,8
43	65,4	61,5	0,0	76,9	61,5	65,4
44	38,5	61,5	0,0	42,3	61,5	42,3
45	57,7	23,1	0,0	50,0	23,1	61,5
46	38,5	19,2	0,0	46,2	19,2	38,5
47	57,7	46,2	0,0	46,2	46,2	53,8
48	42,3	11,5	0,0	38,5	11,5	42,3
49	46,2	53,8	0,0	50,0	53,8	46,2
50	65,4	50,0	0,0	30,8	50,0	65,4
Valor médio	47,2	39,3	0,0	46,6	39,3	45,8

Tabela I.1.4 Precisão da classificação binária descafeinado/café com PCA=1% usando os classificadores *Ensemble*.

Análise ao minuto	<i>Boosted Tress</i>	<i>Bagged Trees</i>	<i>Subspace Discriminant</i>	<i>Subspace KNN</i>	<i>Rusboosted Trees</i>
1	0,0	46,2	46,2	46,2	19,2
2	0,0	50,0	53,8	46,2	19,2
3	0,0	26,9	46,2	30,8	23,1
4	0,0	50,0	3,8	50,0	30,8
5	0,0	38,5	0,0	38,5	30,8
6	0,0	69,2	53,8	69,2	38,5
7	0,0	38,5	0,0	38,5	23,1
8	0,0	57,7	38,5	57,7	34,6

Continua na próxima página

9	0,0	19,2	3,8	26,9	11,5
10	0,0	57,7	0,0	53,8	26,9
11	0,0	42,3	0,0	42,3	23,1
12	0,0	50,0	34,6	46,2	26,9
13	0,0	34,6	42,3	34,6	26,9
14	0,0	30,8	19,2	38,5	23,1
15	0,0	42,3	0,0	42,3	30,8
16	0,0	38,5	0,0	38,5	23,1
17	0,0	50,0	42,3	50,0	23,1
18	0,0	65,4	0,0	65,4	19,2
19	0,0	50,0	26,9	50,0	30,8
20	0,0	42,3	15,4	46,2	30,8
21	0,0	53,8	19,2	53,8	30,8
22	0,0	69,2	50,0	69,2	42,3
23	0,0	30,8	0,0	34,6	23,1
24	0,0	42,3	0,0	42,3	23,1
25	0,0	38,5	46,2	38,5	26,9
26	0,0	69,2	46,2	69,2	19,2
27	0,0	42,3	0,0	42,3	34,6
28	0,0	34,6	38,5	34,6	30,8
29	0,0	61,5	3,8	61,5	19,2
30	0,0	38,5	0,0	38,5	23,1
31	0,0	53,8	38,5	50,0	30,8
32	0,0	65,4	30,8	65,4	34,6
33	0,0	38,5	0,0	38,5	11,5
34	0,0	42,3	42,3	42,3	11,5
35	0,0	65,4	53,8	61,5	26,9
36	0,0	53,8	0,0	53,8	26,9
37	0,0	42,3	53,8	42,3	26,9
38	0,0	38,5	23,1	38,5	19,2
39	0,0	34,6	0,0	34,6	23,1
40	0,0	38,5	0,0	38,5	23,1
41	0,0	46,2	57,7	46,2	11,5
42	0,0	42,3	50,0	42,3	30,8
43	0,0	65,4	73,1	65,4	38,5
44	0,0	38,5	42,3	38,5	23,1
45	0,0	57,7	57,7	57,7	7,7
46	0,0	38,5	46,2	38,5	11,5
47	0,0	57,7	7,7	57,7	26,9
48	0,0	42,3	0,0	42,3	15,4

Continua na próxima página

49	0,0	50,0	0,0	46,2	26,9
50	0,0	65,4	38,5	65,4	23,1
Valor médio	0,0	47,2	24,9	47,2	24,8

I.2 Classificação Binária OF_placebo/OF_cafeína

Tabela I.2.1 Precisão da classificação binária OF_placebo/OF_cafeína com PCA=1% usando os classificadores de árvore de decisão, análise discriminante, regressão logística e *naïve bayes*.

Análise ao minuto	<i>Fine Tree</i>	<i>Medium Tree</i>	<i>Coarse Tree</i>	<i>Lineaar Discriminant</i>	<i>Logist Regression</i>	<i>Naïve Bayes Gaussiane</i>
1	80,8	80,8	80,8	65,4	65,4	69,2
2	57,7	57,7	57,7	69,2	69,2	73,1
3	69,2	69,2	69,2	69,2	65,4	69,2
4	73,1	73,1	73,1	61,5	61,5	57,7
5	50,0	50,0	50,0	61,5	61,5	65,4
6	61,5	61,5	57,7	65,4	65,4	69,2
7	69,2	69,2	69,2	53,8	53,8	65,4
8	61,5	61,5	61,5	57,7	57,7	65,4
9	76,9	76,9	76,9	61,5	61,5	65,4
10	61,5	61,5	61,5	76,9	65,4	76,9
11	80,8	80,8	80,8	0,0	0,0	57,7
12	53,8	53,8	53,8	69,2	69,2	65,4
13	53,8	53,8	57,7	53,8	53,8	50,0
14	57,7	57,7	57,7	61,5	61,5	46,2
15	53,8	53,8	57,7	15,4	15,4	50,0
16	53,8	53,8	53,8	57,7	57,7	61,5
17	53,8	53,8	57,7	65,4	57,7	73,1
18	73,1	73,1	73,1	65,4	65,4	65,4
19	73,1	73,1	73,1	61,5	61,5	69,2
20	69,2	69,2	69,2	65,4	65,4	65,4
21	65,4	65,4	65,4	57,7	57,7	73,1
22	69,2	69,2	69,2	69,2	69,2	69,2
23	65,4	65,4	65,4	69,2	69,2	69,2
24	73,1	73,1	73,1	69,2	69,2	76,9
25	57,7	57,7	57,7	61,5	61,5	57,7
26	73,1	73,1	73,1	65,4	65,4	69,2
27	53,8	53,8	53,8	53,8	53,8	50,0

Continua na próxima página

28	73,1	73,1	73,1	65,4	65,4	65,4
29	69,2	69,2	69,2	76,9	76,9	73,1
30	73,1	73,1	73,1	65,4	65,4	65,4
31	73,1	73,1	73,1	65,4	65,4	69,2
32	80,8	80,8	80,8	69,2	69,2	69,2
33	61,5	61,5	61,5	61,5	61,5	73,1
34	61,5	61,5	61,5	69,2	69,2	65,4
35	61,5	61,5	61,5	57,7	57,7	65,4
36	69,2	69,2	69,2	80,8	76,9	76,9
37	69,2	69,2	69,2	46,2	46,2	61,5
38	65,4	65,4	65,4	69,2	69,2	73,1
39	65,4	65,4	65,4	0,0	0,0	42,3
40	76,9	76,9	76,9	65,4	65,4	69,2
41	65,4	65,4	65,4	0,0	0,0	0,0
42	69,2	69,2	69,2	53,8	53,8	57,7
43	76,9	76,9	76,9	57,7	57,7	65,4
44	53,8	53,8	57,7	57,7	57,7	65,4
45	73,1	73,1	73,1	65,4	65,4	73,1
46	76,9	76,9	76,9	57,7	57,7	65,4
47	65,4	65,4	65,4	61,5	69,2	61,5
48	69,2	69,2	69,2	15,4	19,2	30,8
49	69,2	69,2	69,2	69,2	69,2	76,9
50	73,1	73,1	73,1	61,5	61,5	73,1
Valor médio	66,7	66,7	66,9	57,9	57,6	63,7

Tabela I.2.2 Precisão da classificação binária OF_placebo/OF_cafeína com PCA=1% usando os classificadores SVM.

Análise ao minuto	<i>Linear SVM</i>	<i>Quadratic SVM</i>	<i>Cubic SVM</i>	<i>Fine Gaussian SVM</i>	<i>Medium Gaussian SVM</i>	<i>Coarse Gaussian SVM</i>
1	69,2	73,1	73,1	76,9	0,0	0,0
2	73,1	76,9	57,7	73,1	0,0	0,0
3	76,9	69,2	61,5	76,9	0,0	0,0
4	61,5	69,2	30,8	61,5	0,0	0,0
5	65,4	69,2	76,9	65,4	0,0	0,0
6	73,1	73,1	61,5	76,9	0,0	0,0
7	53,8	73,1	69,2	65,4	0,0	0,0
8	65,4	73,1	34,6	65,4	0,0	0,0
9	65,4	76,9	69,2	73,1	0,0	0,0

Continua na próxima página

10	69,2	73,1	61,5	76,9	0,0	0,0
11	0,0	57,7	69,2	26,9	0,0	0,0
12	69,2	73,1	73,1	73,1	0,0	0,0
13	57,7	61,5	30,8	53,8	0,0	0,0
14	53,8	65,4	61,5	57,7	0,0	0,0
15	26,9	57,7	53,8	11,5	0,0	0,0
16	57,7	65,4	65,4	65,4	0,0	0,0
17	73,1	73,1	73,1	73,1	0,0	0,0
18	65,4	73,1	57,7	65,4	0,0	0,0
19	73,1	69,2	80,8	76,9	0,0	0,0
20	65,4	73,1	34k6	69,2	0,0	0,0
21	69,2	73,1	69,2	76,9	0,0	0,0
22	69,2	69,2	57,7	76,9	0,0	0,0
23	73,1	69,2	34,6	73,1	0,0	0,0
24	76,9	73,1	46,2	76,9	0,0	0,0
25	57,7	69,2	69,2	65,4	0,0	0,0
26	73,1	76,9	46,2	73,1	0,0	0,0
27	50,0	61,5	57,7	3,8	0,0	0,0
28	65,4	69,2	65,4	76,9	0,0	0,0
29	76,9	65,4	69,2	76,9	0,0	0,0
30	65,4	69,2	69,2	65,4	0,0	0,0
31	69,2	73,1	73,1	73,1	0,0	0,0
32	69,2	80,8	73,1	73,1	0,0	0,0
33	73,1	73,1	73,1	69,2	0,0	0,0
34	69,2	73,1	61,5	73,1	0,0	0,0
35	73,1	73,1	50,0	76,9	0,0	0,0
36	76,9	76,9	65,4	76,9	0,0	0,0
37	50,0	76,9	30,8	57,7	0,0	0,0
38	73,1	73,1	53,8	69,2	0,0	0,0
39	0,0	42,3	73,1	0,0	0,0	0,0
40	76,9	73,1	73,1	76,9	0,0	0,0
41	0,0	0,0	50,0	0,0	0,0	0,0
42	53,8	73,1	76,9	57,7	0,0	0,0
43	61,5	76,9	80,8	69,2	0,0	0,0
44	61,5	69,2	42,4	65,4	0,0	0,0
45	73,1	69,2	46,2	73,1	0,0	0,0
46	61,5	76,9	69,2	61,5	0,0	0,0
47	57,7	57,7	53,8	53,8	0,0	0,0
48	30,8	46,2	65,4	19,2	0,0	0,0

Continua na próxima página

49	80,8	80,8	73,1	80,8	0,0	0,0
50	73,1	73,1	76,9	76,9	0,0	0,0
Valor médio	61,5	68,6	61,4	63,1	0,0	0,0

Tabela I.2.3 Precisão da classificação binária OF_placebo/OF_caféina com PCA=1% usando os classificadores KNN.

Análise ao minuto	<i>Fine KNN</i>	<i>Medium KNN</i>	<i>Coarse KNN</i>	<i>Cosine KNN</i>	<i>Cubic KNN</i>	<i>Weighted KNN</i>
1	76,9	76,9	0,0	30,8	76,9	76,9
2	69,2	73,1	0,0	30,8	73,1	69,2
3	65,4	80,8	0,0	30,8	80,8	61,5
4	61,5	65,4	0,0	34,6	65,4	61,5
5	53,8	65,4	0,0	30,8	65,4	53,8
6	69,2	76,9	0,0	30,8	76,9	69,2
7	61,5	57,7	0,0	30,8	57,7	61,5
8	53,8	65,4	0,0	30,8	65,4	53,8
9	69,2	73,1	0,0	38,5	73,1	69,2
10	57,7	65,4	0,0	69,2	65,4	57,7
11	73,1	57,7	0,0	65,4	57,7	76,9
12	69,2	73,1	0,0	73,1	73,1	69,2
13	50,0	65,4	0,0	30,8	65,4	50,0
14	57,7	69,2	0,0	73,1	69,2	57,7
15	65,4	15,4	50,0	76,9	26,9	57,7
16	57,7	65,4	0,0	53,8	65,4	61,5
17	76,9	57,7	0,0	50,0	57,7	69,2
18	57,7	65,4	0,0	42,3	65,4	57,7
19	80,8	65,4	0,0	50,0	65,4	80,8
20	65,4	61,5	0,0	50,0	61,5	69,2
21	73,1	73,1	0,0	30,8	73,1	76,9
22	65,4	73,1	0,0	76,9	73,1	65,4
23	61,5	73,1	0,0	30,8	73,1	61,5
24	76,9	73,1	0,0	73,1	73,1	76,9
25	57,7	69,2	0,0	65,4	69,2	61,5
26	53,8	73,1	0,0	30,8	73,1	50,0
27	61,5	57,7	0,0	61,5	57,7	65,4
28	65,4	76,9	0,0	30,8	76,9	69,2
29	61,5	76,9	0,0	80,8	76,9	65,4
30	69,2	65,4	0,0	50,0	65,4	65,4

Continua na próxima página

31	69,2	73,1	0,0	57,7	73,1	69,2
32	69,2	73,1	0,0	69,2	73,1	73,1
33	69,2	73,1	0,0	69,2	73,1	61,5
34	50,0	73,1	0,0	69,2	73,1	57,7
35	57,7	69,2	0,0	30,8	69,2	69,2
36	57,7	76,9	0,0	80,8	76,9	61,5
37	61,5	69,2	0,0	30,8	69,2	65,4
38	53,8	69,2	0,0	30,8	69,2	53,8
39	57,7	53,8	0,0	69,2	53,8	57,7
40	57,7	69,2	0,0	61,5	69,2	57,7
41	57,7	57,7	0,0	38,5	57,7	57,7
42	73,1	57,7	0,0	50,0	57,7	80,8
43	65,4	76,9	0,0	30,8	76,9	61,5
44	46,2	61,5	0,0	50,0	61,5	46,2
45	61,5	73,1	0,0	50,0	73,1	65,4
46	61,5	65,4	0,0	61,5	65,4	65,4
47	53,8	57,7	0,0	73,1	57,7	61,5
48	65,4	61,5	0,0	38,5	61,5	65,4
49	61,5	80,8	0,0	30,8	80,8	65,4
50	61,5	76,9	0,0	30,8	76,9	65,4
Valor médio	63,0	67,5	1,0	49,5	67,8	64,1

Tabela I.2.4 Precisão da classificação binária OF_placebo/OFF_cafeína com PCA=1% usando os classificadores *Ensemble*.

Análise ao minuto	<i>Boosted Tress</i>	<i>Bagged Trees</i>	<i>Subspace Discriminant</i>	<i>Subspace KNN</i>	<i>Rusboosted Trees</i>
1	0,0	76,9	65,4	76,9	23,1
2	0,0	69,2	69,2	69,2	26,9
3	0,0	65,4	69,2	65,4	34,6
4	0,0	61,5	61,5	61,5	26,9
5	0,0	53,8	61,5	53,8	23,1
6	0,0	69,2	65,4	69,2	30,8
7	0,0	61,5	54,8	61,5	19,2
8	0,0	53,8	57,7	53,8	26,9
9	0,0	69,2	61,5	69,2	23,1
10	0,0	53,9	76,9	57,7	30,8
11	0,0	73,1	0,0	73,1	23,1
12	0,0	65,4	69,2	69,2	26,9

Continua na próxima página

13	0,0	53,8	53,8	50,0	11,5
14	0,0	57,7	61,5	57,7	3,8
15	53,8	11,5	0,0	0,0	65,4
16	0,0	57,7	57,7	57,7	15,4
17	0,0	73,1	65,4	76,9	19,2
18	0,0	57,7	65,4	57,7	26,9
19	0,0	80,8	61,5	80,8	34,6
20	0,0	65,4	65,4	65,4	34,6
21	0,0	73,1	57,7	73,1	11,5
22	0,0	65,4	69,2	65,4	19,2
23	0,0	61,5	69,2	61,5	11,5
24	0,0	76,9	69,2	76,9	23,1
25	0,0	57,7	61,5	57,7	38,5
26	0,0	53,8	65,4	53,8	26,9
27	0,0	61,5	53,8	61,5	23,1
28	0,0	65,4	65,4	65,4	42,3
29	0,0	61,5	76,9	61,5	15,4
30	0,0	69,2	65,4	69,2	34,6
31	0,0	69,2	65,4	69,2	23,1
32	0,0	69,2	69,2	69,2	23,1
33	0,0	69,2	61,5	69,2	30,8
34	0,0	50,0	69,2	50,0	30,8
35	0,0	57,7	57,7	30,8	30,8
36	0,0	57,7	80,8	57,7	30,8
37	0,0	65,4	46,2	61,5	23,1
38	0,0	53,8	69,2	53,8	34,6
39	0,0	57,7	0,0	57,7	34,6
40	0,0	57,7	65,4	57,7	19,2
41	0,0	57,7	0,0	57,7	11,5
42	0,0	73,1	53,8	73,1	3,8
43	0,0	69,2	57,7	65,4	23,1
44	0,0	46,2	57,7	46,2	3,8
45	0,0	61,5	65,4	61,5	15,4
46	0,0	61,5	57,7	61,5	26,9
47	0,0	53,8	61,5	53,8	11,5
48	0,0	65,4	15,4	65,4	7,7
49	0,0	61,5	69,2	61,5	34,6
50	0,0	61,5	61,5	61,5	15,4
Valor médio	1,1	61,9	57,6	61,1	24,2

Referências

- [1] C. Kidd e B. Y. Hayden, “The Psychology and Neuroscience of Curiosity,” *Neuron*, vol. 88, pp. 449-460, 04 November 2015. DOI: 10.1016/j.neuron.2015.09.010
- [2] O. Union, “Health at a Glance: Europe 2020: State of Health in the EU Cycle,” OECD Publishing, Paris, 2020. DOI: 10.1787/82129230-en
- [3] G. Wadley, “How psychoactive drugs shape human culture: A multi-disciplinary perspective,” *Brain Research Bulletin*, Elsevier, vol. 126, pp. 138-151, September 2016. DOI: 10.1016/j.brainresbull.2016.04.008
- [4] R. Seifert e B. Schirmer, “A simple mechanistic terminology of psychoactive drugs: a proposal,” *Naunyn Schmiedebergs Arch Pharmacol*, Springer, vol. 393(8), p. 1331–1339, 2020. DOI: 10.1007/s00210-020-01918-x
- [5] S. Cappelletti, . P. Daria, . G. San e M. Aromatario, “Caffeine: cognitive and physical performance enhancer or psychoactive drug?,” *Current Neuropharmacology*, Bentham Science, p. 13(1): 71–88, 2015. DOI: 10.2174/1570159X13666141210215655
- [6] J. L. Temple, . C. Bernard, . S. E. Lipshultz, . J. D. Czachor, J. A. Westphal e M. A. Mestre, “The Safety of Ingested Caffeine: A Comprehensive Review,” *Frontiers Psychiatry*, vol. 8, p. 80, 26 May 2017. DOI: 10.3389/fpsy.2017.00080
- [7] R. Wierzejska, “Powszechny składnik diety i jej wpływ na zdrowie [Caffeine--common ingredient in a diet and its influence on human health],” *Rocz Panstw Zakl Hig*, National Institute of Public Health NIH - National Research Institute, Warsaw, Poland, vol. 63(2), pp. 141-7, 2012.
- [8] B. Anft, “Friedlieb Ferdinand Runge: A forgotten chemist of the nineteenth century,” *Journal of Chemical Education*, American Chemical Society and Division of Chemical Education, Inc., 1 November 1955. DOI: 10.1021/ed032p566
- [9] M. A. Heckman, J. Weil e E. G. D. Mejia, “Caffeine (1, 3, 7-trimethylxanthine) in Foods: A Comprehensive Review on Consumption, Functionality, Safety, and Regulatory Matters,” *Journal of Food Science*, vol. 75, pp. 77-87, 05 April 2010. DOI: 10.1111/j.1750-3841.2010.01561.x
- [10] B. B. Fredholm, Notes on the history of caffeine use. In: *Methylxanthines.*, vol. 200, Springer, Berlin, Heidelberg, 2010, pp. 1-9. DOI: DOI: 10.1007/978-3-642-13443-2_1
- [11] [Online]. Available: <https://go.drugbank.com/drugs/DB00201>. [Acedido em 05 Junho 2022].
- [12] M. J. Arnaud, “The pharmacology of caffeine,” *Progress in Drug Research*, vol. 31, pp. 273-313, 1987. DOI: 10.1007/978-3-0348-9289-6_9.
- [13] L. Rodas, S. Martinez, A. Aguilo e P. Tauler, “Caffeine supplementation induces higher IL-6 and IL-10 plasma levels in response to a treadmill exercise test,” *Journal of the International Society of Sports Nutrition*, vol. 17, 2020. DOI: 10.1186/s12970-020-00375-4

- [14] F. Alasmari , “Caffeine induces neurobehavioral effects through modulating neurotransmitters,” *Saudi Pharmaceutical Journal*, vol. 28, pp. 445-451, 2020. DOI: 10.1016/j.jsps.2020.02.005
- [15] Z.-L. Huang, Y. Urade e O. Hayaishi, “The role of adenosine in the regulation of sleep,” *Current Topics in Medicinal Chemistry*, vol. 11(8), pp. 1047-57, 2011. DOI: 10.2174/156802611795347654
- [16] T. Porkka-Heiskanen, “Methylxanthines and sleep,” *Handbook of Experimental Pharmacology*, Springer, vol. 200, 2011. DOI: 10.1007/978-3-642-13443-2_12
- [17] L. Lópes-Cruz, J. D. Salamone e M. Correa, “Caffeine and Selective Adenosine Receptor Antagonists as New Therapeutic Tools for the Motivational Symptoms of Depression,” *Frontiers in Pharmacology*, vol. 9, p. 526, 2018. DOI: 10.3389/fphar.2018.00526.
- [18] D. J. David e A. M. Gardier, “Les bases de pharmacologie fondamentale du système sérotoninergique : application à la réponse antidépressive. [The pharmacological basis of the serotonin system: Application to antidepressant response],” *L'Encéphale*, vol. 42, pp. 255-263, 2016. DOI: 10.1016/j.encep.2016.03.012
- [19] B. E. Garrett e R. R. Griffiths, “The role of dopamine in the behavioral effects of caffeine in animals and humans,” *Pharmacology Biochemistry and Behavior*, vol. 57, pp. 533-41, 1997. DOI: 10.1016/s0091-3057(96)00435-2
- [20] A. Nehlig, J. L. Daval e G. Debry, “Caffeine and the central nervous system: mechanisms of action, biochemical, metabolic and psychostimulant effects,” *Brain Research Reviews*, vol. 17, pp. 139-170, 1992. DOI: 10.1016/0165-0173(92)90012-b
- [21] S. I. Walaas , . H. C. J. Hemmings, P. Greengard e A. C. Nairn, “Beyond the dopamine receptor: regulation and roles of serine/threonine protein phosphatases,” *Frontiers in Neuroanatomy*, 2011. DOI: 10.3389/fnana.2011.00050
- [22] M. Voiculescu, I. Ghiță, A. Segărceanu, I. Fulga e O. Coman, “Molecular and pharmacodynamic interactions between caffeine and dopaminergic system,” *Journal of Medicine and Life*, pp. 30-38, 2014. PMID: 27057246.
- [23] K. Okuda, K. Højgaard, L. Privitera , G. Bayraktar e T. Takeuchi, “Initial memory consolidation and the synaptic tagging and capture hypothesis,” *European Journal of Neuroscience*, vol. 54, pp. 6826-6849, 2021. DOI: 10.1111/ejn.14902
- [24] H. Tapiero, G. Mathé, P. Couvreur e K. D. Tew, “II. Glutamine and glutamate,” *Biomedicine & Pharmacotherapy*, vol. 56, pp. 446-57, november 2020. DOI: 10.1016/s0753-3322(02)00285-8
- [25] S. J. Stohs e . V. Badmaev, “A Review of Natural Stimulant and Non-stimulant Thermogenic Agents,” *Phytotherapy Research*, vol. 30, pp. 732-740, May 2016. DOI: 10.1002/ptr.5583
- [26] D. Echeverri, F. R. Montes, M. Cabrera, A. Galán e A. Prieto, “Caffeine's Vascular Mechanisms of Action,” *International Journal of Vascular Medicine*, vol. 2010, p. 834060, 25 August 2010. DOI: 10.1155/2010/834060

- [27] J.-B. Lee e T.-W. Kim, "Ingestion of caffeine links dopamine and 5-hydroxytryptamine release during half immersion in 42°C hot water in a humans," *Journal of Exercise Rehabilitation*, vol. 15, pp. 571-575, 28 August 2019. DOI: 10.12965/jer.1938236.118
- [28] J. Bangsbo, K. Jacobsen, N. Nordberg, N. J. Christensen e T. Graham, "Acute and habitual caffeine ingestion and metabolic responses to steady-state exercise," *Journal of Applied Physiology*, vol. 72, pp. 1297-303, 1992. DOI: 10.1152/jappl.1992.72.4.1297
- [29] L. Dawkins, F.-Z. Shahzad, S. S. Ahmed e C. J. Edmonds, "Expectation of having consumed caffeine can improve performance and mood," *Appetite*, vol. 57, pp. 597-600, December 2011. DOI: 10.1016/j.appet.2011.07.011
- [30] R. P. Barcelos , F. D. Lima, N. R. Carvalho, G. Bresciani e L. F. Royes, "Caffeine effects on systemic metabolism, oxidative-inflammatory pathways, and exercise performance," *Nutrition Research*, vol. 80, pp. 1-17, 2020. DOI: 10.1016/j.nutres.2020.05.005
- [31] K. Xu, Y. H. Xu, J. F. Chen e M. A. Schwarzschild, "Neuroprotection by caffeine: time course and role of its metabolites in the MPTP model of Parkinson's disease," *Neuroscience*, vol. 167, pp. 475-481, 2010. DOI: 10.1016/j.neuroscience.2010.02.020
- [32] D. P. Zaharieva e M. C. Riddell, "Caffeine and glucose homeostasis during rest and exercise in diabetes mellitus," *Applied Physiology, Nutrition, and Metabolism*, vol. 38, pp. 813-22, 2013. DOI: 10.1139/apnm-2012-0471
- [33] A. J. M. Verberne, W. S. Korim, A. Sabetghadam e I. J. Llewellyn-Smith, "Adrenaline: insights into its metabolic roles in hypoglycaemia and diabetes," *British Journal of Pharmacology*, vol. 173, pp. 1425-1437, 2016. DOI: 10.1111/bph.13458
- [34] A. V. Sirotkin e A. Kolesárová, "The anti-obesity and health-promoting effects of tea and coffee," *Physiological Research*, vol. 70, pp. 161-168, 30 April 2021. DOI: 10.33549/physiolres.934674
- [35] A. Iriondo-DeHond, J. A. Uranga, M. D. d. Castillo e R. Abalo, "Effects of Coffee and Its Components on the Gastrointestinal Tract and the Brain–Gut Axis," *Nutrients*, vol. 13, p. 88, 29 December 2020. DOI: 10.3390/nu13010088
- [36] S. E. Rostas e C. McPherson, "Caffeine Therapy in Preterm Infants: The Dose (and Timing) Make the Medicine," *Neonatal Network®: The Journal of Neonatal Nursing*, vol. 38, pp. 365-374, 2019. DOI: 10.1891/0730-0832.38.6.365
- [37] L. Moschino, S. Zivanovic, C. Hartley, D. Trevisanuto, E. Baraldi e C. C. Roehr, "Caffeine in preterm infants: where are we in 2020?," *ERJ Open Research*, vol. 6, pp. 00330-2019, 2020. DOI: 10.1183/23120541.00330-2019
- [38] C. Pickering e J. Grgic, "Caffeine and Exercise: What Next?," *Sports Medicine*, vol. 49, pp. 1007-1030, 2019. DOI: 10.1007/s40279-019-01101-0
- [39] N. S. Guest, T. A. VanDusseldorp, M. T. Nelson, J. Grgic, B. J. Schoenfeld , N. D. M. Jenkins, S. M. Arent, J. Antonio, J. R. Stout, E. T. Trexler, A. E. Smith-Ryan, . E. R. Goldstein, D. S. Kalman

- e B. I. Campbell , “International society of sports nutrition position stand: caffeine and exercise performance,” *Journal of the International Society of Sports Nutrition*, vol. 18, p. 1, 2021. DOI: 10.1186/s12970-020-00383-4
- [40] K. Rodak, I. Kokot e E. M. Krat, “Caffeine as a Factor Influencing the Functioning of the Human Body—Friend or Foe?,” *Nutrients*, vol. 13, p. 3088, 2 September 2021. DOI: 10.3390/nu13093088
- [41] J. Mielgo-Ayuso, D. Marques-Jiménez, I. Refoyo, J. D. Coso, P. León-Guereño e J. Calleja-González, “Effect of Caffeine Supplementation on Sports Performance Based on Differences Between Sexes: A Systematic Review,” *Nutrients*, vol. 11, p. 2313, October 2019. DOI: 10.3390/nu11102313
- [42] J. F. Alopaeus, M. Hellfritsch, T. Gutowski, R. Scherließ, A. Almeida, B. Sarmento, N. Škalko-Basnet e I. Tho , “Mucoadhesive buccal films based on a graft co-polymer – A mucin-retentive hydrogel scaffold,” *European Journal of Pharmaceutical Sciences*, vol. 142, p. 105142, 15 January 2020. DOI: 10.1016/j.ejps.2019.105142
- [43] M. S. Schar, T. I. Omari, R. J. Fraser, A. D. Bersten e S. Bihari , “Disordered swallowing associated with prolonged oral endotracheal intubation in critical illness,” *Intensive Care Medicine*, Springer, vol. 46, p. 140–142, 11 November 2019. DOI: 10.1007/s00134-019-05844-2
- [44] A. F. Borges, C. Silva, J. F. J. Coelho e S. Simões, “Oral films: Current status and future perspectives: I — Galenical development and quality attributes,” *Journal of Controlled Release*, vol. 206, pp. 1-19, 28 May 2015. DOI: 10.1016/j.jconrel.2015.03.006
- [45] R. S. ÖZAKAR¹ e E. ÖZAKAR, “Current Overview of Oral Thin Films,” *Turkish Journal of Pharmaceutical Sciences*, vol. 18, pp. 111-121, February 2021. DOI: 10.4274/tjps.galenos.2020.76390
- [46] M. He, L. Zhu, N. Yang, H. Li e Q. Yang, “Recent advances of oral film as platform for drug delivery,” *International Journal of Pharmaceutics*, vol. 604, p. 120759, 15 July 2021. DOI: 10.1016/j.ijpharm.2021.120759
- [47] S. Karki, H. Kim, S.-J. Na, D. Shin, K. Joo e J. Lee, “Thin films as an emerging platform for drug delivery,” *Asian Journal of Pharmaceutical Sciences*, vol. 11, pp. 559-574, October 2016. DOI: 10.1016/j.ajps.2016.05.004
- [48] G. M. Khalid, . F. Selmin, U. M. Musazzi, . C. G. Gennari, P. Minghetti e F. Cilurzo, “Trends in the Characterization Methods of Orodispersible Films,” *Current Drug Deliver*, Bentham Science Publishers, vol. 18, pp. 935-946, November 2021. DOI: 10.2174/1567201818999201210212557
- [49] K. A. Wickham e L. L. Spriet, “Administration of Caffeine in Alternate Forms,” *Sports Medicine*, vol. 48, p. 79–91, 24 January 2018. DOI: 10.1007/s40279-017-0848-2
- [50] E. Olechno, . A. Puścion-Jakubik, . M. E. Zujko e . K. Socha, “Influence of Various Factors on Caffeine Content in Coffee Brews,” *Foods*, vol. 10, p. 1208, 27 May 2021. DOI 10.3390/foods10061208

- [51] A. N. Gloess, B. Schönbacher, B. Klopprogge, L. D'Ambrosio, K. Chatelain, A. Bongartz, A. Strittmatter, M. Rast e C. Yeretian, "Comparison of nine common coffee extraction methods: instrumental and sensory analysis," vol. 236, pp. 607-627, 30 January 2013. DOI: 10.1007/s00217-013-1917-x
- [52] A. Jeukendrup, "How much caffeine is in coffee?". *Mysportscience*. [Acedido em 13 março de 2022 em <https://www.mysportscience.com/post/2015/06/16/how-much-caffeine-is-in-coffee>]
- [53] J. O. Morales e D. J. Brayden, "Buccal delivery of small molecules and biologics: of mucoadhesive polymers, films, and nanoparticles," *Current Opinion in Pharmacology*, vol. 36, pp. 22-28, October 2017. DOI: 10.1016/j.coph.2017.07.011
- [54] P. Batista, E. Fernandes, F. Ribeiro, A. Moreno, P. Oliveira-Silva e M. Pintado, "Da biotecnologia à psicologia: protocolo neuropsicofisiológico para avaliar filmes orais com cafeína," em *Resumo do 13º Congresso Nacional de Psicologia da Saúde, realizado de 30 de janeiro a 1 de fevereiro de 2020, na Faculdade de Ciências da Saúde da Universidade da Beira Interior, 2021*.
- [55] J. T. Cacioppo, L. G. Tassinari e G. G. Berntson, *Handbook of Psychophysiology*, 3rd ed., New York: Cambridge University Press: Cambridge, 2007.
- [56] G. C. Galbraith, M. L. Kietzman e E. Donchin, *Neurophysiology and Psychophysiology: Experimental and Clinical Applications*, London, UK: Routledge - Taylor & Francis Group, 2021. ISBN 9780367759230
- [57] P. Batista, P. M. Rodrigues, M. Ferreira, A. Moreno, G. Silva, M. Alves, M. Pintado e P. Oliveira-Silva, "Validation of Psychophysiological Measures for Caffeine Oral Films Characterization by Machine Learning Approaches," *Bioengineering (Basel)*, vol. 9, nº 3, p. 144, 2022. DOI: 10.3390/bioengineering9030114
- [58] P. Batista, P. Oliveira-Silva, N. Heym e M. E. Pintado, "Neuropsychophysiological measurements as a tool for neuromodulator oral films evaluation," *International Journal of Pharmaceutical Research*, vol. 13, nº 3, pp. 1051-1062, 2021. DOI: 10.31838/ijpr/2021.13.03.130
- [59] M. C. G. d. Araújo, "Efeito de Estimulantes na Marcha e Postura Humana: Caso da Cafeína, Tese de Mestrado em Engenharia Biomédica," Faculdade de Engenharia da Universidade do Porto, Porto, 2011.
- [60] K. Najarian e R. Splinter, "Biomedical Signal and Image Processing," 2nd ed., Boca Raton, Taylor & Francis Group, 2012. ISBN 978-1-4398-7033-4
- [61] S. A. Alcalá-Corona, S. Sandoval-Motta, J. Espinal-Enríquez e E. Hernández-Lemus, "Modularity in Biological Networks," *Frontiers in Genetics*, vol. 12, p. 701331, 14 September 2021. DOI: 10.3389/fgene.2021.701331
- [62] R. Veeraraghavan, S. Poelzing e R. G. Gourdie, "Intercellular Electrical Communication in the Heart: A New, Active Role for the Intercalated Disk," *Cell Communication and Adhesion*, vol. 21, nº 3, pp. 161-167, June 2014. DOI: 10.3109/15419061.2014.905932

- [63] S. Mori, J. T. Tretter, D. E. Spicer, D. L. Bolender e R. H. Anderson, "What is the real cardiac anatomy?," *Clinical Anatomy*, vol. 32, p. 288–309, April 2019. DOI: 10.1002/ca.23340
- [64] J. G. Betts, K. A. Young, J. A. Wise, E. Johnson, B. Poe, D. H. Kruse, O. Korol, J. E. Johnson, M. Womble e P. DeSaix, "19. The Cardiovascular System: The Heart," em *Anatomy and Physiology*, Houston, Texas, OpenStax, 2013. ISBN 978-1-947172-04-3
- [65] H. Yang, Y. Chen e F. M. Leonelli, "Whole heart modeling - Spatiotemporal dynamics of electrical wave conduction and propagation," *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, vol. 2016, pp. 5575-5578, August 2016. DOI: 10.1109/EMBC.2016.7591990
- [66] D. A. Hooks, M. L. Trew, B. J. Caldwell, G. B. Sands, I. J. LeGrice e B. H. Smaill, "Laminar arrangement of ventricular myocytes influences electrical behavior of the heart," *Circulation Research*, vol. 101, n° 10, pp. 103-12, 9 November 2007. DOI: 10.1161/CIRCRESAHA.107.161075
- [67] A. Russo, J. Regan e C. VanPutte, "20. Circulatory system: the heart," em *Seeley's Anatomy & Physiology*, 10th ed., New York, The McGraw-Hill Global Education Holdings, LLC, 2014, pp. 676-678. ISBN 9780073403632
- [68] "Alamy," 8 março 2016. [Online]. Available: <https://www.alamy.com/normal-heart-electrical-system-illustration-image353193482.html>. [Acedido em 15 fevereiro 2022].
- [69] J. D. Bronzino, "Section I. Biomedical Signal Analysis," em *The Biomedical Engineering Handbook. Medical Devices and Systems.*, 3rd ed., Boca Raton, Taylor & Francis Group, 2006. ISBN 978-0-8493-2122-1
- [70] M. Sampson e A. McGrath, "Understanding the ECG. Part 1: Anatomy and physiology," *British Journal of Cardiac Nursing*, vol. 10, n° 11, 12 Nov 2015. ISSN: 2052-2207. DOI: 10.12968/bjca.2015.10.11.548
- [71] A. L. Goldberger, Z. D. Goldberger e A. Shvilkin, "Chapter 4 - ECG Leads," em *Goldberger's Clinical Electrocardiography. A Simplified Approach.*, Ninth ed., Elsevier, 2018, pp. 21-31. ISBN 978-0-323-40169-2. DOI: 10.1016/C2014-0-03319-9
- [72] . E. A. Ashley e J. Niebauer, "Chapter 3 - Conquering the ECG," em *Cardiology Explained*, 6 ed., London: Remedica, 2004. ISBN 1-901346-22.
- [73] O. Rioul e M. Vetterli, "Wavelets and signal processing," vol. 8, n° 4, pp. 14-38, October 1991. DOI: 10.1109/79.91217
- [74] G. Bachman, L. Narici e E. Beckenstein , "7. Wavelets," em *Fourier and Wavelet Analysis*, First ed., New York, Springer Science+Business Media, LLC, 2000, pp. 411-496. ISBN 978-1-4612-6793-5. DOI: 10.1007/978-1-4612-0505-0
- [75] P. S. Addison, "Wavelet transforms and the ECG: a review," *Physiological Measurement*, vol. 26, n° 5, pp. 155-99, October 2005. DOI: 10.1088/0967-3334/26/5/R01

- [76] G. Kaiser, *A Friendly Guide to Wavelets*, First ed., Boston, MA: Birkhäuser, 2011. ISBN 978-0-8176-8111-1. DOI: 10.1007/978-0-8176-8111-1.
- [77] Mathworks, "Choose Classifier Options," [Online]. Available: <https://www.mathworks.com/help/stats/choose-a-classifier.html>. [Acedido em 21 Março 2022].
- [78] J. W. Woods, "Chapter 4 - 2-D Discrete-Space Transforms," em *Multidimensional Signal, Image, and Video Processing and Coding*, 2nd ed., Academic Press, 2012, pp. 109-151. ISBN 978-0-12-381420-3. DOI: 10.1016/B978-0-12-381420-3.00004-7.
- [79] A. Boggess e F. J. Narcowich, *First Course in Wavelets with Fourier Analysis*, 2nd ed., John Wiley & Sons, Inc, 2009. ISBN 978-0470431177.
- [80] D. A. Castro, S. M. Gomes, A. Gomide, A. S. Oliveira e J. Stolf, "Multiresolution analysis on multidimensional dyadic grids," *HAL Open Science*, 2010.
- [81] P. S. R. Diniz, E. A. B. Da Silva e S. L. Netto, "10. Wavelet Transforms," em *Digital Signal Processing: System Analysis and Design*, 2nd ed., Cambridge University Press, 2010, pp. 660-731. ISBN 9780521887755.
- [82] S. K. Nayak, A. Bit, A. Dey, B. Mohapatra e K. Pal, "A Review on the Nonlinear Dynamical System Analysis of Electrocardiogram Signal," *Journal of Healthcare Engineering*, vol. 2018, p. 2018: 6920420, 2 May 2018. DOI: 10.1155/2018/6920420.
- [83] B. Henry, N. Lovell e F. Camach, "Chapter 1 Nonlinear Dynamics Time Series Analysis," em *Nonlinear Biomedical Signal Processing, Dynamic Analysis and Modeling*, vol. Volume II, Wiley-IEEE Press, 2020, pp. 1-39. ISBN 978-0-780-36012-9.
- [84] E. N. Lorenz, "Deterministic Nonperiodic Flow," *Journal of the Atmospheric Sciences*, vol. 20, nº 2, pp. 130-141, 01 Mar 1963. DOI: 10.1175/1520-0469(1963)020<0130:DNF>2.0.CO;2
- [85] É. Ghys, "The Lorenz Attractor, a Paradigm for Chaos," em *Progress in Mathematical Physics*, vol. 66, Birkhäuser, 2013, pp. 1-54. ISBN 978-3-0348-0697-8. DOI: 10.1007/978-3-0348-0697-8_1.
- [86] R. E. v. Emmerik, S. W. Ducharme, A. C. Amado e J. Hamill, "Comparing dynamical systems concepts and techniques for biomechanical analysis," *Journal of Sport and Health Science*, vol. 5, pp. 3-13, March 2016. DOI: 10.1016/j.jshs.2016.01.013.
- [87] J. M. Nichols e J. D. Nichols, "Attractor reconstruction for non-linear systems: a methodological note," *Mathematical Biosciences*, vol. 171, pp. 21-32, May 2001. DOI: 10.1016/S0025-5564(01)00053-0.
- [88] R. Huffaker, M. Bittelli e R. Rosa, "4 The Features of Chaos," em *Nonlinear Time Series Analysis with R*, Oxford Academic, 2017, pp. 83-122. ISBN 9780191826153. DOI: 10.1093/oso/9780198782933.003.0004.
- [89] A. Casaleggio, S. Braiotta e A. Corana, "Study of the Lyapunov exponents of ECG signals from MIT-BIH database," em *Computers in Cardiology 1995*, 1995. DOI: 10.1109/CIC.1995.482760

- [90] A. Wolf, J. B. Swift, H. L. Swinney e J. A. Vastano, "Determining Lyapunov exponents from a time series," *Physica D: Nonlinear Phenomena*, vol. 16, pp. 285-317, July 1985. DOI: 10.1016/0167-2789(85)90011-9.
- [91] L. S. McCue e A. W. Troesch, "Use of Lyapunov Exponents to Predict Chaotic Vessel Motions," em *Contemporary Ideas on Ship Stability and Capsizing in Waves. Fluid Mechanics and Its Applications.*, vol. 97, Springer, Dordrecht, 2011, pp. 415-432. ISBN 978-94-007-1482-3. DOI: 10.1007/978-94-007-1482-3_23.
- [92] M. T. Rosenstein, J. J. Collins e C. J. D. Luca, "A practical method for calculating largest Lyapunov exponents from small data sets," *Physica D: Nonlinear Phenomena*, vol. 65, nº 1-2, pp. 117-134, 15 May 1993. DOI: 10.1016/0167-2789(93)90009-P.
- [93] R. A. U, O. Faust, N. Kannathal, T. Chua e S. Laxminarayan, "Non-linear analysis of EEG signals at various," *Computer Methods and Programs in Biomedicine*, vol. 80, nº 1, pp. 37-45, 2005. ISSN 0169-2607. DOI: 10.1016/j.cmpb.2005.06.011.
- [94] T. Henriques, M. Ribeiro, A. Teixeira, L. Castro, L. Antunes e C. Costa-Santos, "Nonlinear Methods Most Applied to Heart-Rate Time Series: A Review," *Entropy*, vol. 22, nº 3, p. 309, 9 Mar 2020. DOI: 10.3390/e22030309.
- [95] S. Jerritta, M. Murugappan, W. Khairunizam e S. Yaacob, "Emotion Detection from QRS Complex of ECG Signals Using Hurst Exponent for Different Age Groups," *2013 Humaine Association Conference on Affective Computing and Intelligent Interaction*, pp. 849-854, 2013. DOI: 10.1109/ACII.2013.159.
- [96] M. Gospodinov, E. Gospodinova e G. Georgieva-Tsaneva, "Chapter 7 - Mathematical methods of ECG data analysis," em *Healthcare Data Analytics and Management. Advances in ubiquitous sensing applications for healthcare.*, Academic Press, 2019, pp. 177-209. ISBN 978-0-12-815368-0. DOI: 10.1016/B978-0-12-815368-0.00007-5.
- [97] A. K. Mishra e S. Raghav, "Local fractal dimension based ECG arrhythmia classification," *Biomedical Signal Processing and Control*, vol. 5, p. 114-123, 2010. DOI: 10.1016/j.bspc.2010.01.002.
- [98] T. Azizi, "On the fractal geometry of different heart rhythms," *Chaos, Solitons & Fractals: X*, vol. 9, p. 100085, December 2022. DOI:10.1016/j.csf.2022.100085.
- [99] R. L. GomesLuiz, L. C. M. Vanderlei, D. M. Garner, F. M. Vanderlei e V. E. Valenti, "Higuchi Fractal Analysis of Heart Rate Variability is Sensitive during Recovery from Exercise in Physically Active Men," *MedicalExpress*, vol. 4, nº 3, 5 May 2017. DOI: 10.5935/MedicalExpress.2017.03.02.
- [100] A. Kalauzi, T. Bojic e A. Vuckovic, "Modeling the relationship between Higuchi's fractal dimension and Fourier spectra of physiological signals," *Medical & Biological Engineering & Computing*, vol. 50, p. 689-699, 2012. DOI: 10.1007/s11517-012-0913-9.

- [101] J. L. Semmlow, "3 FREQUENCY TRANSFORMATIONS," em *Circuits, Signals and Systems for Bioengineers. A MATLAB-Based Introduction.*, Third ed., Academic Press, 2018, pp. 69-120. ISBN 978-0-12-809395-5. DOI: 10.1016/C2015-0-06052-X.
- [102] A. Grami, "Chapter 3 - Signals, Systems, and Spectral Analysis," em *Introduction to Digital Communications*, Academic Press, 2016, pp. 41-150. ISBN 978-0-12-407682-2. DOI: 10.1016/B978-0-12-407682-2.00003-X.
- [103] S. I. McClean, "Data Mining and Knowledge Discovery," em *Encyclopedia of Physical Science and Technology*, Third ed., Academic Press, 2003, pp. 229-246. ISBN 978-0-12-227410-7. DOI: 10.1016/B0-12-227410-5/00845-0.
- [104] B. S. Handa, C. H. Roney, C. Houston, N. A. Qureshi, . X. Li, D. S. Pitche, R. A. Chowdhury, P. B. Lim, E. Dupont, S. A. Niederer, C. D. Cantwell, N. S. Peters e F. S. Ng, "Analytical approaches for myocardial fibrillation signals," *Computers in Biology and Medicine*, vol. 102, p. 315–326, 1 November 2018. DOI: 10.1016/j.compbimed.2018.07.008.
- [105] M. Borowska, "Entropy-Based Algorithms in the Analysis of Biomedical Signals," em *Studies in Logic, Grammar and Rhetoric*, First ed., vol. 43, 2016, pp. 21-32. ISBN 978–83–7431–464–0. DOI: doi.org/10.1515/slgr-2015-0039.
- [106] P. M. Coq , W. Legnani e R. Armentano, "Detection of Arrhythmic Cardiac Signals from ECG Recordings Using the Entropy–Complexity Plane," *Proceedings*, MDPI - Publisher of Open Access Journals, vol. 46, n° 1, p. 8, 2020. DOI: doi.org/10.3390/ecea-5-06693.
- [107] A. Kalali, S. Richerson, E. Ouzunova, R. Westphal e B. Miller, "Chapter 16 - Digital Biomarkers in Clinical Drug Development," em *Handbook of Behavioral Neuroscience*, Bentham Science Publishers, vol. 29, Academic Press, 2019, pp. 229-238. DOI: 10.2174/1567201818999201210212557.
- [108] B. Rim, N.-J. Sung, S. Min e M. Hong, "Deep Learning in Physiological Signal Data: A Survey," *Sensors*, vol. 20, n° 4, p. 969, 11 February 2020. DOI: 10.3390/s20040969.
- [109] T. Davenport e R. Kalakota, "The potential for artificial intelligence in healthcare," *Future Healthcare Journal*, vol. 6, n° 2, p. 94–98, 6 June 2019. DOI: 10.7861/futurehosp.6-2-94.
- [110] F. S. Nahm, "Receiver operating characteristic curve: overview and practical use for clinicians," *Korean Journal of Anesthesiology*, vol. 75, n° 1, p. 25–36, Feb 2022. DOI: 10.4097/kja.21209.
- [111] A. N. Kamarudin, T. Cox e R. Kolamunnage-Dona, "Time-dependent ROC curve analysis in medical research: current methods and applications," *BMC Medical Research Methodology*, vol. 17, p. 53, 2017. DOI :10.1186/s12874-017-0332-6.
- [112] K. Hajian-Tilaki, "Receiver Operating Characteristic (ROC) Curve Analysis for Medical Diagnostic Test Evaluation," *Caspian Journal of Internal Medicine*, Spring, vol. 4, n° 2, p. 627–635, 2013. PMID: 24009950.

- [113] T. C. F. Polo e H. A. Miot, "Aplicações da curva ROC em estudos clínicos e experimentais," *Jornal Vascular Brasileiro*, vol. 19, nº 4, Dezembro 2020. ISSN 1677-7301. DOI: 10.1590/1677-5449.200186.
- [114] A. Rani, N. Kumar, J. Kumar, J. Kumar e N. K. Sinha, "Chapter 6 - Machine learning for soil moisture assessment," em *Deep Learning for Sustainable Agriculture. A volume in Cognitive Data Science in Sustainable Computing.*, Academic Press, 2022, pp. 143-168. ISBN 978-0-323-85214-2. DOI: 10.1016/C2020-0-02363-7.
- [115] S. Cohen, "Chapter 2: The basics of machine learning: strategies and techniques," em *Artificial Intelligence and Deep Learning in Pathology*, Elsevier, 2021, pp. 13-40. ISBN 978-0-323-67538-3. DOI: 10.1016/B978-0-323-67538-3.00002-6.
- [116] H. E. Solberg, "Discriminant analysis," *CRC critical reviews in clinical laboratory sciences*, vol. 9, nº 3, pp. 209-242, 1978. DOI: 10.3109/10408367809150920.
- [117] T. Jombart, S. Devillard e F. Balloux, "Discriminant analysis of principal components: a new method for the analysis of genetically structured populations," *Bmc Genetics*, vol. 11, p. 94, Oct 2010. DOI: 10.1186/1471-2156-11-94.
- [118] B. Ghogh e M. Crowley, "Linear and Quadratic Discriminant Analysis: Tutorial," 07 2019 June. [Acedido em 18 de fevereiro de 2022 em https://www.researchgate.net/publication/333650066_Linear_and_Quadratic_Discriminant_Analysis_Tutorial].
- [119] S. Dreiseitl e L. Ohno-Machado, "Logistic regression and artificial neural network classification models: a methodology review," *Journal of Biomedical Informatics*, vol. 35, nº 5-6, pp. 352-359, October 2002. DOI: 10.1016/S1532-0464(03)00034-0.
- [120] A. Bartosik e H. Whittingham, "Chapter 7 - Evaluating safety and toxicity," em *The Era of Artificial Intelligence, Machine Learning, and Data Science in the Pharmaceutical Industry*, Academic Press, 2021, pp. 119-137. ISBN 978-0-12-820045-2. DOI: doi.org/10.1016/C2019-0-01262-9.
- [121] H.-A. Park, "An Introduction to Logistic Regression: From Basic Concepts to Interpretation with Particular Attention to Nursing Domain," *Journal of Korean Academy of Nursing*, vol. 42, nº 2, pp. 154-164, 30 April 2013. DOI: 10.4040/jkan.2013.43.2.154.
- [122] R. Rachh, S. Allagi e S. B. K., "Chapter 11 - Machine learning algorithms for prediction of heart disease," em *Demystifying Big Data, Machine Learning, and Deep Learning for Healthcare Analytics*, Academic Press, 2021, pp. 247-275. ISBN 978-0-12-821633-0. DOI: 10.1016/C2019-0-03651-5.
- [123] S. Misra e H. Li, "Chapter 9 - Noninvasive fracture characterization based on the classification of sonic wave travel times," em *Machine Learning for Subsurface Characterization*, Gulf Professional Publishing, 2020, pp. 243-287. ISBN 978-0-12-817736-5. DOI: 10.1016/B978-0-12-817736-5.00009-0.

- [124] S. Krishnan, “6 - Machine learning for biomedical signal analysis,” em *Biomedical Signal Analysis for Connected Healthcare*, Academic Press, 2021, pp. 223-264. ISBN 978-0-12-813086-5. DOI: 10.1016/B978-0-12-813086-5.00006-2.
- [125] G. F. M. Souza, A. C. Netto, A. H. A. Melani, M. A. C. Michalski e R. F. Silva, “Chapter 6 - Engineering systems' fault diagnosis methods,” em *Reliability Analysis and Asset Management of Engineering Systems. A volume in Advances in Reliability Science.*, Elsevier, 2022, pp. 165-187. ISBN 978-0-12-823521-8. DOI: 10.1016/C2020-0-00478-0.
- [126] P. Ambika, “Chapter Thirteen - Machine learning and deep learning algorithms on the Industrial Internet of Things (IIoT),” em *Advances in Computers. The Digital Twin Paradigm for Smarter Systems and Environments: The Industry Use Cases.*, First ed., vol. 117, 2020, pp. 321-338. ISBN 978-0-12-818756-2. DOI: 10.1016/bs.adcom.2019.10.007.
- [127] I. H. Witten, E. Frank e M. A. Hall, “Chapter 6 - Implementations: Real Machine Learning Schemes,” em *Data Mining: Practical Machine Learning Tools and Techniques. A volume in The Morgan Kaufmann Series in Data Management Systems.*, Third ed., Morgan Kaufmann, 2011, pp. 191-304. ISBN 978-0-12-374856-0. DOI: 10.1016/C2009-0-19715-5.
- [128] Q. Li, Z. Wen e B. He, “Adaptive Kernel Value Caching for SVM Training,” *IEEE Transactions on Neural Networks and Learning Systems*, vol. 31, nº 7, pp. 2376-2386, Jul 2020. DOI: 10.1109/TNNLS.2019.2944562.
- [129] P. D. Caie, N. Dimitriou e O. Arandjelović, “Chapter 8 - Precision medicine in digital pathology via image analysis and machine learning,” em *Artificial Intelligence and Deep Learning in Pathology*, Elsevier, 2021, pp. 149-173. ISBN 978-0-323-67538-3. DOI: 10.1016/C2018-0-02465-2.
- [130] J. Han, M. Kamber e J. Pei, “9 - Classification: Advanced Methods,” em *Data Mining: Concepts and Techniques. A volume in The Morgan Kaufmann Series in Data Management Systems.*, Third ed., Morgan Kaufmann, 2012, pp. 393-442. ISBN 978-0-12-381479-1. DOI: 10.1016/C2009-0-61819-5.
- [131] Q. Chaudhry, J. Chrétien, M. Craciun, G. Guo, F. Lemke, J.-A. Müller, D. Neagu, N. Piclin, M. Pintore e P. Trundle, “Chapter 4 - Algorithms for (Q)SAR model building,” em *Quantitative Structure-Activity Relationships (QSAR) for Pesticide Regulatory Purposes*, Elsevier Science, 2007, pp. 111-147. ISBN 978-0-444-52710-3. DOI: 10.1016/B978-0-444-52710-3.X5001-0.
- [132] D. Chanal, N. Y. Steiner, R. Petrone, D. Chamagne e M.-C. Péra, “Online Diagnosis of PEM Fuel Cell by Fuzzy C-Means Clustering,” em *Encyclopedia of Energy Storage*, vol. 2, Elsevier, 2020, pp. 359-393. ISBN 978-0-12-819730-1. DOI: 10.1016/B978-0-12-819723-3.00099-8.
- [133] P. Nadkarni, “Chapter 10 - Core Technologies: Data Mining and “Big Data”,” em *Clinical Research Computing. A Practitioner's Handbook.*, Academic Press, 2016, pp. 187-204. ISBN 978-0-12-803130-8. DOI: doi.org/10.1016/C2014-0-03836-1.

- [134] T. M. D. Ebbels, "Chapter 7 - Non-linear Methods for the Analysis of Metabolic Profiles," em *The Handbook of Metabonomics and Metabolomics*, Elsevier Science, 2007, pp. 201-226. ISBN 978-0-444-52841-4. DOI: 10.1016/B978-044452841-4/50008-4.
- [135] R. C. Neath e M. S. Johnson, "Discrimination and Classification," em *International Encyclopedia of Education*, Third ed., Elsevier Science, 2010, pp. 135-141. ISBN 978-0-08-044894-7.
- [136] M. R. H. Samadi, "Eye Tracking with EEG life-style. Thesis for: PhD. Project: Constrained SVM-ICA for reliable EEG source separation", ResearchGate, 2015. [Acedido em 03 de maio de 2022 em https://www.researchgate.net/publication/322358139_Eye_Tracking_with_EEG_life-style]
- [137] I. Zoppis, G. Mauri e R. Dondi, "Kernel Machines: Applications," em *Reference Module in Life Sciences. Encyclopedia of Bioinformatics and Computational Biology.*, Elsevier, 2019. DOI: 10.1016/B978-0-12-809633-8.20343-9
- [138] Y. Yu, K. Diamantaras, T. McKelvey e S. Y. Kung, "Chapter 6 - Kernel Subspace Learning for Pattern Classification," em *Adaptive Learning Methods for Nonlinear System Modeling*, Butterworth-Heinemann, 2018, pp. 127-147. ISBN 978-0-12-812976-0. DOI: 10.1016/B978-0-12-812976-0.00008-7.
- [139] I. Kononenko e M. Kukar, "Chapter 10 - Statistical Learning," em *Machine Learning and Data Mining*, Woodhead Publishing, 2007, pp. 259-274. ISBN 978-1-904275-21-3. DOI: 10.1533/9780857099440.259.
- [140] J. Boccard e S. Rudaz, "Chapter 27 - Mass Spectrometry Metabolomic Data Handling for Biomarker Discovery," em *Proteomic and Metabolomic Approaches to Biomarker Discovery*, Academic Press, 2013, pp. 425-445. ISBN 978-0-12-394446-7. DOI: 10.1016/C2011-0-06994-6.
- [141] J. Wang, H. Lu, K. N. Plataniotis e J. Lu, "Gaussian kernel optimization for pattern classification," *Pattern Recognition*, vol. 42, nº 7, pp. 1237-1247, July 2009. DOI: 10.1016/j.patcog.2008.11.024.
- [142] E. Vocaturo, D. Perna e E. Zumpano, "Machine Learning Techniques for Automated Melanoma Detection," em *2019 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, 2019. DOI 10.1109/BIBM47256.2019.8983165.
- [143] V. N. Gudivada, M. T. Irfan, E. Fathi e D. L. Rao, "Chapter 5 - Cognitive Analytics: Going Beyond Big Data Analytics and Machine Learning," em *Handbook of Statistics. Cognitive Computing: Theory and Applications.*, vol. 35, Elsevier, 2016, pp. 169-205. ISBN 978-0-444-63744-4. DOI: 10.1016/bs.host.2016.07.010.
- [144] Y. Yang, "Chapter 4 - Ensemble Learning," em *Temporal Data Mining via Unsupervised Ensemble Learning*, Elsevier, 2017, pp. 35-56. ISBN 978-0-12-811654-8. DOI: 10.1016/C2016-0-01428-6.
- [145] P. Wittek, "9 - Boosting," em *Quantum Machine Learning. What Quantum Computing Means to Data Mining.*, Academic Press, 2014, pp. 89-95. ISBN 978-0-12-800953-6. DOI: 10.1016/B978-0-12-800953-6.00009-8.

- [146] D. Talia, P. Trunfio e F. Marozzo, "Chapter 1 - Introduction to Data Mining," em *Data Analysis in the Cloud. Models, Techniques and Applications. A volume in Computer Science Reviews and Trends.*, Elsevier, 2015, pp. 1-25. ISBN 978-0-12-802881-0. DOI: 10.1016/C2014-0-02172-7.
- [147] S. Simske, "Chapter 1 - Introduction, overview, and applications," em *Meta-Analytics. Consensus Approaches and System Patterns for Data Analysis.*, Morgan Kaufmann, 2019, pp. 1-98. ISBN 978-0-12-814623-1. DOI: 10.1016/C2017-0-02114-6.
- [148] X. Yang, Y. Wang, R. Byrne, G. Schneider e S. Yang, "Concepts of Artificial Intelligence for Computer-Assisted Drug Discovery," *Chemical Reviews. Published by American Chemical Society.*, July 2019. DOI: 10.1021/acs.chemrev.8b00728.
- [149] A. S. Ashour, Y. Guo, A. R. Hawas e G. Xu, "Ensemble of subspace discriminant classifiers for schistosomal liver fibrosis staging in mice microscopic images," *Health Information Science and Systems*, vol. 6, nº 1, p. 21, December 2018. DOI 10.1007/s13755-018-0059-8.
- [150] A. Derhab, M. Guerroumi , A. Gumaiei, L. Maglaras, M. A. Ferrag, M. Mukherjee e F. A. Khan , "Blockchain and Random Subspace Learning-Based IDS for SDN-Enabled Industrial IoT Security," *Sensors*, vol. 19, nº 14, p. 3119, 2019.
- [151] M. Skurichina e R. P. W. Duin , "Bagging and the Random Subspace Method for Redundant Feature Spaces," *International Workshop on Multiple Classifier Systems: Multiple Classifier Systems*, MDPI - Multidisciplinary Digital Publishing Institute, pp. 1-10, 22 June 2001. DOI: 10.3390/s19143119.
- [152] M. Zounemat-Kermani, O. Batelaan, M. Fadaee e R. Hinkelmann, "Ensemble machine learning paradigms in hydrology: A review," *Journal of Hydrology*, vol. 598, p. 126266, July 2021. DOI: 10.1016/j.jhydrol.2021.126266
- [153] H. Liu, "Chapter 5 - Data mining and processing for train unmanned driving systems," em *Unmanned Driving Systems for Smart Trains* , Elsevier, 2021, pp. 211-252. ISBN 978-0-12-822830-2. DOI: 10.1016/B978-0-12-822830-2.00005-2.
- [154] C. Lindner, "Chapter 1 - Automated Image Interpretation Using Statistical Shape Models," em *Statistical Shape and Deformation Analysis. Methods, Implementation and Applications.*, Academic Press, 2017, pp. 3-32. ISBN 978-0-12-810493-4. DOI: 10.1016/B978-0-12-810493-4.00002-X.
- [155] W. Mao e F.-Y. Wang, "Chapter 8 - Cultural Modeling for Behavior Analysis and Prediction," em *New Advances in Intelligence and Security Informatics*, Academic Press, 2012, pp. 91-102. ISBN 978-0-12-397200-2. DOI: 10.1016/B978-0-12-397200-2.00008-7.
- [156] C. Seiffert, T. M. Khoshgoftaar, J. V. Hulse e A. Napolitano, "RUSBoost: A Hybrid Approach to Alleviating Class Imbalance," *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans*, vol. 40, nº 1, pp. 185-197, Jan 2010. DOI: 10.1109/TSMCA.2009.2029559.

- [157] P. Refaeilzadeh, L. Tang e H. Liu , “Cross-Validation,” em *Encyclopedia of Database Systems*, Springer, Boston, MA, 2009, p. 532–538. ISBN 978-0-387-39940-9. DOI: 10.1007/978-0-387-39940-9_565.
- [158] P. M. d. L. Rodrigues, “Diagnóstico da Doença de Alzheimer Com Base no Electroencefalograma. Relatório Final do Trabalho de Projecto apresentado para para obtenção do grau de Mestre em Tecnologia Biomédica.,” Escola Superior de Tecnologia e de Gestão, 2011.
- [159] J. B. Brown, “Classifiers and their Metrics Quantified,” *Molecular Informatics*, pp. 37(1-2):1700127, January 2018. DOI: 10.1002/minf.201700127.
- [160] P. M. Castro, P. Fonte, A. Oliveira, A. R. Madureira, B. Sarmento e M. E. Pintado, “Optimization of two biopolymer-based oral films for the delivery of bioactive molecules,” *Materials Science and Engineering C*, Elsevier, vol. 76, pp. 171-180, 2017. DOI: 10.1016/j.msec.2017.02.173
- [161] P. Batista, P. M. Castro, A. R. Madureira, B. Sarmento e M. Pintado, “Recent insights in the use of nanocarriers for the oral delivery of bioactive proteins and peptides,” *Peptides*, vol. 101, pp. 112-123, 2018. DOI: 10.1016/j.peptides.2018.01.002.
- [162] Biopac, “Introductory ECG Guide”. [Acedido em 17 de dezembro de 2021 em <https://www.biopac.com/ecg-guide/>].
- [163] V. Gupta, S. Sachdeva e N. Dohare, “Chapter 8 - Deep similarity learning for disease prediction,” em *Trends in Deep Learning Methodologies. Algorithms, Applications, and Systems. A volume in Hybrid Computational Intelligence for Pattern Analysis.*, Academic Press, 2021, pp. 183-206. ISBN 978-0-12-822226-3. DOI: 10.1016/C2019-0-04635-3.
- [164] M. D’Aloia, A. Longo e M. Rizzi , “Noisy ECG Signal Analysis for Automatic Peak Detection,” *Information*, MDPI - Publisher of Open Access Journals, vol. 10, nº 2, p. 35, 2019. DOI: 10.3390/info10020035.
- [165] T. Araújo , J. P. Teixeira e P. M. Rodrigues, “Smart-Data-Driven System for Alzheimer Disease Detection through Electroencephalographic Signals,” *Bioengineering*, pp. 9(4), 141, 13 March 2022. DOI: 10.3390/bioengineering9040141.