

# Incorporação de Biossensores no Soldado do Futuro

José Miguel Silva  
Academia Militar  
Lisboa, Portugal  
silva.jmm2@exercito.pt

João Torres  
Academia Militar  
Lisboa, Portugal  
torres.jpn@exercito.pt

Maria João  
Academia Militar  
Lisboa, Portugal  
mariajoaomartins2@gmail.com

**Resumo**—Atualmente, e cada vez mais, a utilização de biossensores está presente no nosso quotidiano, sendo que a sua aplicação surge em várias áreas da nossa sociedade. Como tal, e dada a sua importância, a evolução dos mesmos é uma grande prioridade da comunidade científica, de forma a estabelecer diversas formas de tirar proveito destes e torná-los cada vez mais eficientes.

Este artigo insere-se no estudo de biossensores com recurso a eléctrodos pré-gelificados e focou-se na análise da capacidade de extração de informação relativa à qualidade dos treinos, estado emocional dos militares, carga e consciência cognitiva, assim como a condição física do Soldado do Futuro, através dos seus sinais biológicos, extraídos e processados pelos biossensores e microcontrolador da BITalino, de forma automática. Esta análise materializou-se experimentalmente através da classificação de dois estados emocionais, calmo e *stress*, para os quais se atingiu até 98,18% de exatidão.

**Palavras-Chave:** Biossensores; Microcontrolador; Informação; Automática.

## I. INTRODUÇÃO

A avaliação da condição de um militar pode ser uma tarefa desafiadora na medida em que existem algumas situações complexas nas quais não há a possibilidade de ter um profissional de saúde presente para avaliar a situação médica dos militares e, por vezes, quando há essa possibilidade, pode não haver meios de obtenção da informação fisiológica para ser interpretada por estes em tempo útil. Sendo que, nas situações mais críticas, o tempo para obter o diagnóstico é relativamente limitado.

Através das novas tecnologias é possível desenvolver modelos que, de forma automática, permitam que seja feita uma deteção de anomalias fisiológicas e emocionais. Estes modelos tornam possível alertar os profissionais de saúde da necessidade de realizar testes de despiste em resposta à deteção de alguma anomalia que ocorra, com o objetivo de reduzir os efeitos de problemas detetados de forma tardia. Posto isto, o desenvolvimento de soluções com recurso a modelos de aprendizagem automática, no sentido de facilitar o trabalho dos profissionais de saúde, tem aumentado gradualmente.

Os meios utilizados atualmente para prever anomalias fisiológicas consistem no acompanhamento em situações de elevado esforço físico por equipas médicas e análises ao sangue e à urina. Estes métodos são insuficientes e têm vindo a mostrar-se pouco eficazes na prevenção do agravamento de problemas de saúde, principalmente em ambiente de instrução.

No presente trabalho é abordado o tema dos biossensores e as características pelas quais a sua implementação no meio

militar é vantajosa, recorrendo a componentes da PLUX Wireless Biosignals S.A.

O principal objetivo deste trabalho foi realizar um estudo sobre as informações que os sensores do *BITalino (r)evolution Plugged Kit* fornecem e realizar uma extração de sinais fisiológicos permitindo, de forma automática, diferenciar dois estados emocionais distintos, calmo e *stress*, com o intuito de tirar ilações das maneiras de tornar estes sistemas úteis no meio militar. Por forma a atingir estes objetivos, foram conduzidos testes experimentais a par de um estudo teórico aprofundado.

Quanto ao desenvolvimento e inserção deste tipo de tecnologias para fins militares, os estados-membros da União Europeia devem reger-se pela *Standard Architecture for Soldier Systems (STASS)* [1], por forma a existir estandardização, interoperabilidade, forma de carregamento e portabilidade entre todas as nações pertencentes.

## II. ESTADO DA ARTE

### A. Biossensores

Atualmente, o estudo e aplicação de biossensores tem, cada vez mais, a atenção dos engenheiros. Para além das diversas aplicações clássicas no ramo da medicina, criou-se um novo paradigma que utiliza uma analogia de computação física [2] e pode ser descrita como computação fisiológica. As novas aplicações dos biossensores tornaram-se, por este motivo, um tema de ampla relevância na comunidade dos engenheiros e, por consequência, há grandes evidências de que o estudo dos sinais biológicos e dos seus sensores é um ramo de interesse em crescimento.

O primeiro biossensor foi desenvolvido, em 1962, por Clark e Lyons que imobilizava Glicose Oxidase (GOx), com a finalidade de quantificar a concentração de glicose de uma amostra [3], [4]. Descreveram como fazer melhores sensores eletromecânicos (PH, polarográfico, potenciométrico ou condutométrico), através de um único eléctrodo de oxigénio, acoplado a um contra-eléctrodo.

Os biossensores têm inúmeras vantagens, sobrepondo-se às análises convencionais, por permitirem que o estudo dos sinais biológicos de um indivíduo seja menos dependente de instalações laboratoriais de análise. Por este motivo, o custo dos processos com recurso a biossensores, comparativamente aos convencionais, torna-os ainda mais apreciados [5].

Os biossensores têm um papel com importância temporalmente crescente na área do reconhecimento de emoções no geral, sendo estas um aspeto importante na comunicação e

interação entre pessoas. Apesar das emoções serem intuitivamente conhecidas, é difícil definir precisamente “emoção”. O filósofo grego Aristóteles descrevia as emoções como um estímulo de avaliação de experiências com base no potencial de gerar dor ou prazer. Ao longo dos anos, têm vindo a surgir outras definições, contudo, nos dias de hoje, ainda não há um consenso relativamente a estas [6]. De forma a compreender estas emoções, através de sinais captados por sensores, é necessário fazer uso de estratégias de classificação, tal como o modelo dimensional na figura 1.

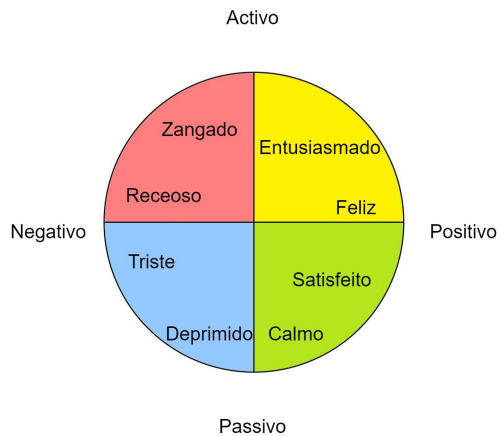


Figura 1. Modelo Dimensional de Emoções [6].

Apesar da dificuldade de defini-la com precisão, a emoção está sempre presente e é um fator importante na vida humana. O estado emocional das pessoas influencia fortemente a sua forma de comunicar e, também, a sua atuação e produtividade. Desta forma, este é um tema de elevada relevância no meio militar para o aumento da produtividade no dia-a-dia, bem como nas missões em território nacional e no estrangeiro.

### B. Aprendizagem automática

A aprendizagem automática, como um ramo da inteligência artificial, tem vindo a desempenhar um papel cada vez mais importante na investigação científica nos últimos anos. Foi descrita por Arthur Samuel, como o campo de estudo que dá aos computadores a capacidade de aprender sem ser explicitamente programados [7].

Os algoritmos de aprendizagem podem ser divididos em vários tipos de modelos de acordo com as características do problema em questão.

O presente artigo foi desenvolvido com recurso a aprendizagem supervisionada, que consiste na utilização de um algoritmo que gera uma função para relacionar determinadas características de um conjunto de dados com uma saída desejada. É construído um modelo a partir de conjuntos de dados com o objetivo de fazer previsões em novos dados. Os algoritmos supervisionados podem ser subdivididos em problemas de classificação e regressão. Por um lado, nos problemas de classificação o objetivo é atribuir um resultado de entre um conjunto de categorias, como por exemplo *stress*

ou calmo. Por outro lado, a regressão tem como saída final um valor numérico e não uma categoria.

## III. METODOLOGIA EXPERIMENTAL

### A. Recolha de dados

Com o objetivo de extrair sinais biológicos para o desenvolvimento dos processos de classificação, foi realizado um teste a 33 alunos, dos quais 29 da Academia Militar e 4 da Academia da Força Aérea. Este teste consistiu na observação de dois vídeos, com 6 minutos cada, tendo o primeiro o objetivo de induzir um estado emocional calmo, na zona verde do modelo dimensional de emoções 1, e o segundo de *stress*, na zona do amarelo e vermelho do mesmo modelo.

Estes vídeos foram visualizados pela maioria dos alunos através dos óculos de realidade virtual Pico 2, sendo que apenas 5 dos alunos fizeram o teste observando os vídeos no ecrã de um computador portátil. Na imagem 2, é possível observar o ambiente de teste utilizado.

De referir que 5, dos 33 testes realizados, foram descartados devido a erros ocorridos na realização dos mesmos, pelo que, apenas foram considerados 28 testes.



Figura 2. Aluno em teste, com os óculos de realidade virtual Pico 2, com os sinais biológicos, em tempo real, no monitor.

Para a obtenção de informação biológica de relevo, o local de colocação dos eléctrodos foi bastante importante, na medida em que esta determina tanto a qualidade do sinal, bem como o conforto do indivíduo em teste. Posto isto, os eléctrodos foram dispostos conforme a figura 3.

Na realização do Eletrocardiograma (ECG) foram colocados eléctrodos, a vermelho na figura, nos pulsos esquerdo e direito (positivo e negativo, respetivamente), por serem partes do corpo mais acessíveis e confortáveis para a sua colocação, do que o peito (local mais comum para a realização deste teste) e a diminuição na amplitude do sinal relativa não ser relevante [8].

Em relação à Eletromiografia (EMG), os eléctrodos foram colocados por cima da sobrancelha, a azul na figura, mais concretamente nos músculos occipitofrontal e corrugador do supercílio, de acordo com Yumiao et al. [9]. Estes fazem referência a um velho ditado chinês, “o amor pode ser transmitido pelas sobrancelhas”, que apoia a tese da importância das sobrancelhas para o reconhecimento de emoções.

Os eléctrodos de medição da Atividade Eletrodérmica (AED), a verde na figura, foram dispostos na palma da mão esquerda conforme indica o documento da BITalino [10].

Por fim, a referência, a preto na figura, é colocada no cotovelo por ser uma zona óssea, como indicado nos artigos anteriores supra-referidos.




Figura 3. Disposição dos eléctrodos.

**B. Preparação de dados**

Os testes deram origem a ficheiros `.txt` com várias colunas, das quais três são relevantes para o estudo. Os valores foram retirados a uma frequência de 1000 Hz por cada um dos sensores, EMG, ECG e AED.

A quantidade de valores extraídos foi calculada com o intuito de ser utilizado o número máximo de valores de cada teste. Desta forma, as dimensões da matriz onde os dados biométricos foram posteriormente carregados foi preparada para desenvolver os processos de aprendizagem automática.

O número de linhas médio dos testes foi 402141 e o mínimo 370606, sendo que com o mínimo delimitou-se os dados a utilizar. Foram carregados, para a matriz a utilizar nos processos de aprendizagem automática, os dados a partir da linha 10000, devido à existência de ruído inicial, associado ao movimentos dos indivíduos no começo do teste. As últimas 15000 linhas foram retiradas, devido ao movimento após o término do vídeo e retirada dos óculos de realidade virtual, antes de ser parada a captação dos dados biométricos.

Deste modo, os limites utilizados foram as linhas 10000 e 360000, que cria e guarda a matriz de trabalho, exemplificada na figura 4, com dimensões de 56 linhas por 1050000 colunas, num ficheiro `.npy`.




Figura 4. Representação da matriz de trabalho.

A opção de utilizar os ficheiros `.npy` para armazenar os dados deveu-se à grande velocidade do mesmo para carregar os valores, comparativamente aos ficheiros `.txt` e `.csv`. Concluiu-se que os ficheiros `.txt` demoravam 4 minutos e 20 segundos a serem distribuídos pela matriz de trabalho, enquanto o ficheiro `.npy` permitia ter a mesma matriz, pronta a utilizar, em 0,18 segundos, levando a um decréscimo de relevo no tempo gasto a testar novos algoritmos de classificação.

**C. Seleção de características**

Como foi referido em III-B, o *dataset* é composto por uma matriz numérica de dimensão 56 por 1050000. Estas dimensões traduzem-se numa elevada complexidade do modelo e tornam-se num obstáculo ao alcance de boas predições. Por este motivo, as dimensões do *dataset* foram reduzidas, levando ao declínio do custo de aprendizagem e a melhores predições com modelos mais simples.

Um dos métodos de seleção de características mais comum consiste na seleção das *k* melhores características. Esta técnica pode ser aplicada com recurso à biblioteca `sklearn` [11]. Este método retira cada característica do conjunto de dados e compara-o com o resultado. Após ter comparado todos os atributos, são deixadas *k* características no novo conjunto de dados resultante.

Este é um dos métodos mais simples, porém, deve ser utilizado antes de se recorrer a métodos de seleção mais complexos, porque, muitas vezes, mostra bons resultados. Este método funciona de acordo com um critério estatístico, que deve ser escolhido de acordo com as características do problema a resolver. Dado que o problema de trabalho tem uma entrada numérica e uma saída categórica, as mais adequadas são a *Analysis of Variance* (ANOVA) e a Kendall's.

Visto que, o método `SelectkBest`, da biblioteca `sklearn` [11], apenas suporta o critério estatístico ANOVA, foi este o aplicado. Este método permite avaliar a dependência da expectativa matemática ou variação do resultado sobre as características selecionadas. Assim, é possível avaliar se esta característica é significativa para a obtenção do resultado.

**D. Métodos de aprendizagem e classificação**

Após a seleção de características, foram aplicados diversos algoritmos de classificação para distinguir a observação do primeiro vídeo, codificado com o valor lógico 0, do segundo vídeo, codificado com o valor lógico 1, correspondentes ao estado emocional calmo e *stress*, respetivamente. Para além disso, foram otimizados os parâmetros dos algoritmos que se demonstraram mais adequados a este problema específico.

1) *Análise discriminante linear*: A análise discriminante linear é conhecida como uma ferramenta de redução de dimensões, contudo é também um método robusto de classificação. É caracterizado por ser um método simples e por produzir resultados bons e interpretáveis. Quando são abordados problemas reais para serem resolvidos por uma classificação automática, este costuma ser um dos primeiros métodos utilizados para fazer uma avaliação comparativa, antes de serem aplicados outros mais complexos.

2) *Regressão logística*: A regressão logística é um dos modelos lineares estatísticos mais frequentemente utilizados, enquadrado na aprendizagem supervisionada para classificação. Os modelos lineares consistem numa ou mais variáveis independentes que têm uma relação com a variável dependente.

Deste modo, com o objetivo de melhorar os resultados finais, foram alteradas as percentagens de treino e teste. Estas percentagens correspondem à quantidade de dados que é utilizada para aprendizagem e, posteriormente, para testar o algoritmo. Atribuindo ao parâmetro  $k$ , que representa o número de conjuntos de dados, os valores 4, 5 e 6, as percentagens utilizadas de treino e teste são, respetivamente, 75% e 25%, 80% e 20% e 83,34% e 16,66%.

Para além disso, variou-se logaritmicamente o parâmetro de regularização,  $C$ , de 0,1 a 1000. Este parâmetro pode ser visto como a capacidade do classificador aceitar classificações erradas no conjunto de dados, de forma a generalizar corretamente com os dados de treino, isto é, valores mais pequenos de  $C$ , traduzem-se numa maior regularização.

Por fim, testou-se várias funções *solver*. Cada *solver* tenta encontrar os pesos dos parâmetros que minimizam uma função de custo, foram testados o *newton-cg*, *lbfgs*, *liblinear*, *sag* e *saga*.

3) *Support vector classification*: O principal objetivo da *Support Vector Classification* (SVC) é criar uma fronteira num conjunto de dados composto por elementos pertencentes a duas classes diferentes. Esta é uma ferramenta de aprendizagem muito poderosa que se baseia num método estatístico com base na aprendizagem estatística e minimização do erro, a fim de obter a capacidade de identificar a classe de um novo conjunto de dados.

Mais concretamente, através de vetores de características, é criado um hiperplano ou, por vezes, um conjunto de hiperplanos, que atua como um limite entre as classes. Na figura 5 é possível observar um exemplo de aprendizagem dos limites de decisão (ou seja, do hiperplano) pela SVC [12].




Figura 5. Representação de um exemplo de hiperplano.

Posto isto, a fim de melhorar os valores finais de validação, foram alteradas as percentagens de treino e teste, tal como na

regressão logística III-D2. Para além disso, variou-se também logaritmicamente o parâmetro de regularização  $C$  de 0,1 a 1000, sendo que, tal como anteriormente referido, valores mais pequenos deste parâmetro traduzem-se numa maior regularização.

Por fim, testou-se várias funções *kernel*. Este parâmetro foca-se na escolha das fronteiras do hiperplano entre classes e, para este problema, foram testados os *kernel linear*, *rbf*, *sigmoid* e *poly*.

4) *Classificador ridge*: A regressão *ridge* é uma regressão linear, por esse motivo, assume uma relação linear entre as variáveis de entrada e a variável de saída. Com uma única variável de entrada, esta relação é representada por uma linha, sendo que com mais dimensões, esta relação pode ser pensada como um hiperplano que liga as variáveis de entrada à de saída. Os coeficientes do modelo são encontrados através de um processo de otimização que procura minimizar a soma do erro quadrático entre as previsões e os valores de saída.

O regressor de *ridge* tem uma variante classificadora, o *RidgeClassifier*. Este classificador converte, primeiramente, as saídas binárias a classificar em  $\{-1, 1\}$  e, de seguida, trata o problema como uma tarefa de regressão, otimizando o objetivo supra-referido. A classe prognosticada corresponde ao sinal da previsão do regressor.

Este modelo, apesar de não ser muito utilizado, pode levar a bastante bons resultados de validação. Para além disso, a perda de mínimos quadrados penalizada, utilizada pelo *RidgeClassifier*, permite personalizar o método para o problema a resolver com a alteração dos *solvers* (*auto*, *svd*, *cholesky*, *lsqr*, *sparse\_cg*, *sag* e *saga*) com perfis de desempenho computacionais distintos, bem como, com o parâmetro  $Alpha$  que corresponde a  $\frac{1}{2C}$ , sendo  $C$  o parâmetro de regularização utilizado noutros modelos lineares como, por exemplo, a regressão logística e a SVC linear [11].

5) *Certificação dos algoritmos*: A avaliação dos classificadores é bastante importante no processo de classificação, são através dos métodos de validação escolhidos que o desempenho do modelo é avaliado, permitindo melhorar a sua performance.

Existem diversas formas de avaliar um algoritmo, sendo uma das mais utilizadas, o valor de exatidão. Porém, por si só, pode não ser suficiente para garantir a eficácia dos modelos, na prática ou num novo conjunto de dados. Por esse motivo, foram utilizadas também a precisão, a sensibilidade e o *f1-score*, calculadas através das métricas de confusão, relacionadas com a verdade do conjunto de dados e a previsão do modelo, onde TP, TN, FP, e FN denotam, respetivamente, verdadeiro positivo (*true positive*), verdadeiro negativo (*true negative*), falso positivo (*false positive*) e falso negativo (*false negative*).

A matriz de confusão apresenta os resultados sob a forma de uma tabela com duas entradas, uma com as classes reais e outra com as classes previstas pelo modelo, esta pode ser observada na figura 6.

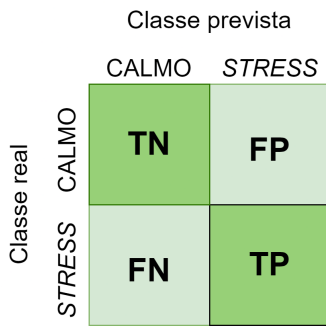


Figura 6. Representação da matriz de confusão.

No contexto do presente artigo, os TP são as instâncias classificadas como *stress* e nas quais o indivíduo em teste estava realmente a ver o vídeo que induzia esse estado emocional. Os FP são os casos em que as classes são previstas como *stress*, mas na realidade o indivíduo estava a ver o vídeo que induzia o estado emocional calmo. Por outro lado, os TN correspondem aos casos em que as instâncias foram classificadas como calmo e o vídeo em observação foi o correspondente e os FN são as situações em que as classes são identificadas como calmo, mas na realidade o vídeo era o de *stress*.

Os métodos de avaliação utilizados, calculados através das métricas de confusão supra-referidas, são dados pelas fórmulas seguidamente apresentadas.

$$exatidão = \frac{TP + TN}{TP + FP + TN + FN} \quad (1)$$

$$precisão = \frac{TP}{TP + FP} \quad (2)$$

$$sensibilidade = \frac{TP}{TP + FN} \quad (3)$$

$$f1\_score = 2 * \frac{precisão * sensibilidade}{precisão + sensibilidade} \quad (4)$$

Para além destes métodos de avaliação, utilizou-se a técnica de *cross validation*, que consiste em dividir o conjunto de dados em parcelas de dados. Por sua vez, estes dividem-se nos subconjuntos para estimar os parâmetros do modelo e para a validação do mesmo, denominados anteriormente como grupos de treino e teste.

O método usado para aplicar esta técnica foi o *k-fold*, este divide os dados em *k* conjuntos do mesmo tamanho e, daí em diante, passa a utilizar um conjunto para teste e os restantes *k-1* para estimar os parâmetros, fazendo-se deste modo o cálculo das métricas de validação do modelo. O processo é realizado *k* vezes alternando o conjunto de teste, como é possível observar na figura 7 [13].

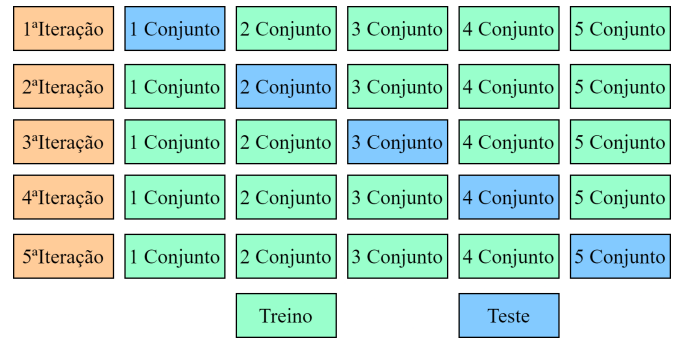


Figura 7. Esquema de divisão e execução do método *k-fold*, com *k* = 5.

Cada *k* vezes que esta técnica é realizada, são calculadas as métricas de validação. Por forma a calcular a média destas de cada iteração, foram criados quatro vetores, correspondentes a cada métrica, de forma a armazenar estes valores para serem utilizados no término do processo.

#### IV. RESULTADOS E DISCUSSÃO

Primeiramente, o desenvolvimento dos processos de recolha e preparação dos dados foi ultrapassado sem muitas dificuldades, sendo que o passo mais importante destas tarefas foi a decisão e otimização do local onde colocar os elétrodos. Por esse motivo, foram completados rapidamente com sucesso.

De seguida, no início do desenvolvimento do projeto, como é comum em muitos trabalhos de aprendizagem automática, não se utilizou nenhum método de seleção de características, o que levou a grandes tempos de processamento e maus resultados, sendo que neste tipo de trabalhos são categorizados como maus, todos os resultados abaixo de 60% de exatidão. Verificou-se, desta forma, que este passo é crucial para a obtenção de bons resultados de classificação.

Quanto aos métodos de aprendizagem e classificação, foram testados diversos, sendo que foram apresentados neste artigo, os quatro melhores. Verificou-se que apesar do número de testes, correspondente às linhas da matriz de trabalho ser reduzido, a quantidade extensa de características quer da matriz completa, com 1050000 colunas, quer da otimizada, com 100000 colunas, levou a que métodos adequados a grandes quantidades de informação fossem mais eficientes e igualmente eficazes.

Por fim, os métodos de validação demonstraram que os resultados foram muito bons, tendo em conta que neste tipo de trabalhos são categorizados como muito bons todos os resultados com exatidão superior a 90%. Estes resultados podem ser observados na tabela I. Pode-se, desta forma, concluir que é possível através destes sensores identificar com elevada exatidão alterações emocionais e retirar a ilação que através destes sensores temos a capacidade de detetar anomalias físicas, sendo o principal obstáculo desta deteção o ruído associado ao movimento.

Tabela I  
RESULTADOS FINAIS.

Análise discriminante linear							
tol	Partições	Solver	Exatidão	Precisão	Sensibilidade	F1 score	Tempo (s)
0,001	5	svd	0,9469	1	0,9142	0,9512	5,15
Regressão logística							
C	Partições	Solver	Exatidão	Precisão	Sensibilidade	F1 score	Tempo (s)
1	5	lbfgs	0,9818	0,9714	1	0,9777	10,6247
0,1	5	lbfgs	0,9636	0,9428	1	0,96	11,8165
100	6	liblinear	0,9629	0,9428	1	0,9481	7,5339
Support vector classification							
C	Partições	Kernel	Exatidão	Precisão	Sensibilidade	F1 score	Tempo (s)
0,1	5	linear	0,9636	0,9428	1	0,9666	1,8947
0,1	6	linear	0,9629	0,9428	1	0,9686	2,6934
0,1	6	polinomial	0,9629	0,9428	1	0,9686	2,3256
Classificador ridge							
Alpha	Partições	Solver	Exatidão	Precisão	Sensibilidade	F1 score	Tempo (s)
100	6	auto	0,9629	0,9428	1	0,9686	1,1385
100	6	cholesky	0,9629	0,9428	1	0,9686	1,2957
10	6	svd	0,9629	0,9428	1	0,9686	3,652

## V. CONCLUSÕES

Através da elaboração do presente artigo foi possível colocar em prática alguns dos conhecimentos teórico-práticos adquiridos ao longo do percurso académico na Academia Militar e no Instituto Superior Técnico. Para além disso, ter contacto com as ferramentas OpenSignals [14], Spyder [15] e Scikit-learn [11] foi essencial para o desenvolvimento do produto final.

O principal objetivo do trabalho foi explorar a capacidade de, através de modelos de aprendizagem automática, classificar dois estados emocionais, com recurso a dados fisiológicos extraídos por biossensores, e otimizar esta classificação, de forma a obter os melhores resultados de validação no menor tempo possível.

Primeiramente, foi efetuada a introdução do presente trabalho, enquadrando o tema dos biossensores como tecnologias de interesse para fins militares e definindo os objetivos do mesmo.

Numa segunda fase, para obter bases teóricas, foi estudado o estado da arte dos temas abordados no restante artigo, nomeadamente, biossensores e aprendizagem automática. Estes conteúdos estão largamente aprofundados e o estudo dos biossensores está, maioritariamente, direcionado para os ramos da medicina e do desporto sendo, desta forma, facilmente transposta a sua aplicação no Soldado do futuro e, consequentemente, no meio militar.

Por fim, foi necessário efetuar a recolha de dados, através de testes realizados a 33 alunos, com o objetivo de desenvolver processos de classificação. De forma a otimizar as predições obtidas, recorreu-se a diversos modelos de classificação e estes foram analisados, cuidadosamente, através das métricas de validação, para verificar qual a melhor solução para o problema em questão.

Terminado o trabalho, é possível afirmar que a "Incorporação de Biossensores no Soldado do Futuro" é um tema de relevo e bastante atual.

## REFERÊNCIAS

- [1] Jose Luis Delgado Gamella. Stass ii standard architecture for soldier systems-data management and infrastructure. <https://eda.europa.eu/docs/default-source/documents/stass-ii-information-paper.docx>, 2017. accessed 06/01/2022.
- [2] Dan O'Sullivan and Tom Igoe. *Physical Computing: Sensing and Controlling the Physical World with Computers*. Course Technology Press, Boston, MA, USA, 2004.
- [3] Audrey Sassolas, Loïc J. Blum, and Béatrice D. Leca-Bouvier. Immobilization strategies to develop enzymatic biosensors. *Biotechnology Advances*, 30(3):489–511, 2012.
- [4] Shruti Nambiar and John T. W. Yeow. Conductive polymer-based sensors for biomedical applications. *Biosensors & bioelectronics*, 26 5:1825–32, 2011.
- [5] Anthony Turner, Isao Karube, and George Wilson. *Biosensor fundamentals and applications*, 1987.
- [6] Robert Horlings, Dragos Dacu, and Léon Rothkrantz. Emotion recognition using brain activity, 2008.
- [7] Gio Wiederhold and John McCarthy. Arthur samuel: Pioneer in machine learning. *IBM Journal of Research and Development*, 36:329 – 331, 1992.
- [8] Andrea Němcová, Lucie Maršánová, Radovan Smisek, Martin Vitek, and Jana Kolářová. Recommendations for ecg acquisition using bitalino. [https://www.researchgate.net/publication/308984068\\_RECOMMENDATIONS\\_FOR\\_ECG\\_ACQUISITION\\_USING\\_BITALINO](https://www.researchgate.net/publication/308984068_RECOMMENDATIONS_FOR_ECG_ACQUISITION_USING_BITALINO), 2016. accessed 10/02/2022.
- [9] Yumiao Chen, Zhongliang Yang, and Jiangping Wang. Eyebrow emotional expression recognition using surface emg signals. *Neurocomputing*, 168, 2015.
- [10] Electrodermal activity (eda) sensor user manual, 2020. accessed 5/12/2021.
- [11] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, and E. Duchesnay. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12:2825–2830, 2011.
- [12] Abhishek Kumar and Maheshkumar H. Kolekar. Machine learning approach for epileptic seizure detection using wavelet analysis of eeg signals. In *2014 International Conference on Medical Imaging, m-Health and Emerging Communication Systems (MedCom)*, pages 412–416, 2014.
- [13] Cross-validation: evaluating estimator performance. accessed 28/07/2022.
- [14] Opensignals (r)evolution visualize your biosignals, 2021. accessed 13/11/2021.
- [15] Pierre Raybaut. Spyder-documentation. Available online at: [pythonhosted.org](http://pythonhosted.org), 2009.