



INSTITUTO
UNIVERSITÁRIO
DE LISBOA

Deteção automática de sinais de depressão em redes sociais em contexto de Covid-19

Daniela Cristina da Silva Carlos

Mestrado em Engenharia Informática

Orientador:

Doutor Ricardo Daniel Santos Faro Marques Ribeiro, Professor Associado,
Iscte – Instituto Universitário de Lisboa

Co-Orientador:

Doutor Fernando Manuel Marques Batista, Professor Associado,
Iscte – Instituto Universitário de Lisboa

Novembro, 2021



TECNOLOGIAS
E ARQUITETURA

Departamento de Ciências e Tecnologias da Informação

**Deteção automática de sinais de depressão em redes sociais
em contexto de Covid-19**

Daniela Cristina da Silva Carlos

Mestrado em Engenharia Informática

Orientador:

Doutor Ricardo Daniel Santos Faro Marques Ribeiro, Professor Associado,
Iscte – Instituto Universitário de Lisboa

Co-Orientador:

Doutor Fernando Manuel Marques Batista, Professor Associado,
Iscte – Instituto Universitário de Lisboa

Novembro, 2021

Resumo

A saúde mental é um tema muito abordado nos dias de hoje, especialmente desde que a pandemia começou, uma vez que o distanciamento social fez com que as pessoas tivessem de criar alternativas de comunicação, tendo recorrido cada vez mais às redes sociais para esse efeito. Muitas pessoas não querem ser tratadas ou não assumem que têm depressão, resultando muitas vezes em casos mais graves, como episódios depressivos, levando até a situações de suicídio.

Deste modo, para evitar as situações já referidas, é necessário criar técnicas de deteção automática de sinais de depressão com base em informação produzida por um determinado indivíduo. Existem diversos trabalhos que referem vários métodos de deteção bem como analisam a depressão numa perspetiva das ciências cognitivas. Nesta dissertação pretende-se detetar sinais depressivos cruzando as palavras que compõem uma determinada publicação textual de duas formas diferentes: com léxicos já existentes ou com um dicionário que contém as palavras relacionadas com depressão, provenientes de fontes distintas. Igualmente, pretende-se aplicar algoritmos de aprendizagem automática considerando o histórico de um determinado utilizador para que os resultados sejam comparados ao estado de arte.

Foi possível concluir que, as pessoas depressivas normalmente utilizam uma diversidade de palavras no seu vocabulário o que torna complicada a deteção recorrendo a léxicos. No entanto, se forem consideradas as palavras negativas, os resultados vão ser melhorados. Os algoritmos genéricos aplicados, conseguiram melhorar os resultados em termos de precisão mas em relação à cobertura e à medida f ficaram aquém do estado de arte.

Palavras chave

Saúde Mental, Depressão, Covid-19, Aprendizagem Automática, Twitter, Reddit

Abstract

Mental health is a topic that has been discussed a lot these days, especially since the pandemic started, since the social distance meant that people had to create communication alternatives, having increasingly resorted to social networks for this purpose. Many people do not want to be treated or do not assume they have depression, often resulting in more serious cases, such as depressive episodes, even leading to suicide.

Thus, to avoid the aforementioned situations, it is necessary to create techniques for the automatic detection of depression signs based on information produced by a specific individual. There are several works that refer to various detection methods as well as analyzing depression from a cognitive science perspective. This dissertation aims to detect depressive signs by crossing the words that make up a given textual publication in two different ways: with existing lexicons or with a dictionary that contains words related to depression, from different sources. Likewise, it is intended to apply automatic learning algorithms considering the history of a given user so that the results can be compared to the state of the art.

It was possible to conclude that depressed people usually use a variety of words in their vocabulary which makes detection complicated using lexicons. However, if negative words are considered, the results will be improved. The applied generic algorithms were able to improve the results in terms of precision, but in relation to coverage and measure f, they were below the state of the art.

Keywords

Mental Health, Depression, Covid-19, Machine Learning, Twitter, Reddit

Agradecimentos

Acknowledgements

Esta dissertação não teria sido possível sem o apoio dos meus orientadores Fernando e Ricardo, que por mais que soubessem que eu tinha de gerir o trabalho com a tese, sempre deram a força e motivação para que conseguisse finalizá-la com sucesso.

Aos meus pais, Maria e José, que me ajudaram a lidar com os momentos de maior *stress* e desmotivação e que deram um apoio fundamental na escrita desta dissertação.

À minha amiga, Patricia, que sempre soube dizer as palavras mais adequadas a cada situação, dando apoio e ajuda quando era necessário. Também pelo facto de nunca deixar de acreditar que eu ia conseguir e de compreender e ajudar a superar as minhas frustrações e desmotivações que surgiram ao longo deste percurso.

Ao resto dos meus amigos, que partilharam palavras de coragem e superação para que eu nunca desmotivasse e perdesse o foco do essencial.

Por último dedico esta dissertação, a todas as pessoas que já passaram por grandes desafios na vida e que por mais barreiras impostas, conseguiram superá-los com suor, sangue e lágrimas.

Lisboa, 30 de Novembro de 2021

Daniela Carlos

Conteúdo

1	Introdução	1
1.1	Motivação	2
1.2	Objetivos e Questões de Investigação	3
1.3	Metodologia	4
1.4	Estrutura do Documento	5
2	Depressão e Redes Sociais	7
2.1	Depressão e Saúde Mental	7
2.1.1	Dados	8
2.1.2	Tipos de Depressão	9
2.1.3	Prevenção	10
2.1.4	Tratamento	10
2.2	Redes Sociais	12
2.3	Depressão e Redes Sociais	12
2.4	A influência do Covid-19 nos sintomas depressivos	15
2.5	Conclusões	21
3	Trabalho Relacionado	23
3.1	Depressão Nas Ciências Cognitivas	23
3.2	Deteção Automática da Depressão	24
3.2.1	Pré-processamento dos Dados	26
3.2.2	Deteção de Depressão	26
3.3	Conclusões	26
4	Deteção Automática da Depressão	29

4.1	Experiências ao Nível do <i>Post</i>	29
4.1.1	<i>Dataset</i>	29
4.1.2	Pré-Processamento	30
4.1.3	Metodologia	30
4.1.4	Análise de Resultados	33
4.2	Experiências ao Nível do Histórico do Utilizador	40
4.2.1	<i>Dataset</i>	40
4.2.2	Pré-Processamento	41
4.2.3	<i>Features</i> Mais Importantes	41
4.2.4	Metodologias	41
4.2.5	Análise de Resultados	44
4.3	Conclusões	45
5	Conclusões e Trabalho Futuro	47
	Bibliografia	49

Lista de Figuras

1.1	Impacto da saúde mental na rede social <i>Twitter</i> [54]	4
1.2	Alterações na saúde mental por cada rede social influenciadas pelas notícias do Covid-19 [20]	5
1.3	Experiência efetuada com os <i>posts</i> da rede social <i>Reddit</i>	6
1.4	Experiências efetuadas com os <i>posts</i> da rede social <i>Twitter</i>	6
2.1	Evolução da proporção de casos nas doenças mentais mais comuns em Portugal Continental: depressão, demência e ansiedade [60]	8
2.2	Evolução dos casos de depressão desde 1990 até 2019 por região da OMS [25]	9
2.3	Percentagem de entrevistados que recorreram a profissionais de saúde devido a problemas mentais - Eurobarómetro [69]	11
2.4	Evolução do número de pessoas que utilizam as redes sociais desde 2004 até 2019 [12]	13
2.5	Evolução do tempo gasto nas redes sociais desde 2012 até 2019 [27]	13
2.6	Utilização das redes sociais por faixa etária [15]	14
2.7	Resultados obtidos no estudo #StatusOfMind representando as cinco redes sociais com maior impacto na saúde mental [54]	15
2.8	Evolução da taxa de jovens da Geração Z que se sentem mais sozinhos, desde 1991 até 2015 [6]	16
2.9	Evolução do tempo dispendido pelos jovens da geração Z no convívio presencial [6]	17
2.10	Figura comparativa de depressão em adultos, antes e durante a pandemia [22]	18
2.11	Atividades mais investidas durante a pandemia [19]	18
2.12	Efeitos da pandemia nos jovens [9]	19
2.13	Taxa de adultos nos Estado Unidos com sintomas depressivos declarado, antes e durante a pandemia [45]	19

2.14	Porcentagem de estudantes que reportaram problemas psíquicos, antes e durante a pandemia [55]	20
2.15	Porcentagem de pessoas que se sentiram mais sozinhas, ansiosas ou depressivas durante a pandemia [68]	20
3.1	Modelo circumplexo de Russel - lado esquerdo representa a depressão [78] . .	24
3.2	Palavras associadas a cada sintoma depressivo e estímulo psicossocial causador de <i>stress</i> , extraídas de anotações manuais e de bibliotecas.	25
4.1	Extração de falsos negativos e positivos obtidos na primeira experiência	34
4.2	Extração de falsos negativos e positivos obtidos na segunda experiência	35
4.3	Extração de falsos negativos e positivos obtidos com o cruzamento com o léxico SDD	36
4.4	Extração de falsos negativos e positivos obtidos com o cruzamento com o léxico Choudhury	37
4.5	Extração de falsos negativos e positivos obtidos com a junção de palavras do léxico criado	38
4.6	Top das trinta palavras mais utilizadas em <i>tweets</i> depressivos	39
4.7	Palavras caracterizadas com polaridade negativa nos <i>tweets</i>	39
4.8	Resultados obtidos por Count Vectorizer variando o número de <i>features</i> e parâmetros.	42
4.9	Resultados obtidos utilizando TF-IDF variando o número de <i>features</i> e de parâmetros.	43
4.10	Resultados em termos de cobertura obtidos nas experiências (utilizando o modelo de TF-IDF com 500.000 <i>features</i> , mínimo <i>document frequency</i> 5 e máximo <i>document frequency</i> 0,7 e o modelo de aprendizagem automática SVC Linear), <i>over sampling</i> e <i>under sampling</i>	43
4.11	Resultados em termos de precisão obtidos nas experiências (utilizando o modelo de TF-IDF com 500.000 <i>features</i> , mínimo <i>document frequency</i> 5 e máximo <i>document frequency</i> 0,7 e o modelo de aprendizagem automática SVC Linear), <i>over sampling</i> e <i>under sampling</i>	44
4.12	Resultados em termos da medida <i>f</i> obtidos nas experiências (utilizando o modelo de TF-IDF com 500.000 <i>features</i> , mínimo <i>document frequency</i> 5 e máximo <i>document frequency</i> 0,7 e o modelo de aprendizagem automática SVC Linear), <i>over sampling</i> e <i>under sampling</i>	45

Lista de Tabelas

2.1	Tratamento das perturbações psíquicas em Portugal em 2014 [58]	12
4.1	Exemplo de <i>tweets</i> com marcação de depressão	30
4.2	Resultados obtidos por léxico. A experiência 1 do NRC VAD tem em conta A e D negativos e A>D e A>V e a experiência 2 tem em conta apenas A e D negativos.	33
4.3	Resultados obtidos por fonte.	36
4.4	Resultados obtidos com a junção de todas as palavras do dicionário.	37
4.5	Resultados obtidos adicionando as palavras negativas	40

Introdução

A depressão é uma das doenças mentais que mais afeta a população mundial. Muitos dos casos de suicídio ou até de incapacidade¹ podem advir dessa doença. Em 2015 ocorreram perto de 80.000 suicídios. Segundo dados da OMS, três em cada quatro pessoas, na Europa, que sofrem de depressão, não recebem tratamento adequado [72]. Isto deve-se ao facto de a doença estar associada a vários sintomas comuns a outras doenças (como tristeza, perda de interesse ou prazer, falta de autoestima, perturbações do sono ou perda de apetite, sensação de cansaço e baixo nível de concentração) [71] o que pode dificultar na deteção e na atribuição de diagnóstico mais eficaz à situação. Também o facto de as pessoas estarem relutantes a assuntos que envolvam doenças mentais pode contribuir para que o diagnóstico não seja feito no devido tempo. Deste modo, torna-se necessário a criação de técnicas que ajudem os especialistas na área da psicologia e da psiquiatria a detetar os sintomas, mas também que a sociedade esteja preparada para aceitar com normalidade estes temas.

Uma vez que as redes sociais, atualmente, são utilizadas como um meio de fuga à solidão e como uma forma de partilha de sentimentos e emoções, estas podem ser um auxílio na deteção de sintomas depressivos. Por outro lado, o impacto negativo destas quando utilizadas em demasia pode evidenciar a depressão nos utilizadores devido a diversos fatores que vão ser referidos no Capítulo 2.

Em Março de 2020, começou a surgir na sociedade um vírus proveniente da China, denominado SARS-Cov-2 que se espalhou pelo Mundo. Este vírus afetou a sociedade de tal forma que, devido ao número elevado de casos diários bem como internamentos e cuidados intensivos, foi necessário definir medidas de contingência que vieram a alterar a rotina e o dia-a-dia das pessoas. De modo a ser possível desacelerar o aumento de casos, foi aplicado o confinamento obrigatório. Com este, deixou de se trabalhar fora de casa, passando a efetuar-se o teletrabalho. Igualmente os estabelecimentos de ensino, comerciais, públicos foram encerrados bem como evitados os convívios sociais. Deste modo, começou-se a recorrer cada vez mais às redes sociais de modo a permitir a comunicação entre pessoas, sem pôr em causa a sua segurança e para contrariar o isolamento. Esta necessidade aumentou bruscamente na medida em que as pessoas começaram a passar cada vez mais horas nas redes sociais, tanto a publicar como a visualizar ou comentar conteúdos. Também a utilização destas como modo de comunicação entre familiares ou amigos aumentou.

¹YLD - Anos de vida por incapacidade

Com a pandemia deu-se mais relevância à saúde mental. De tal forma que começaram a surgir diversos estudos, que pretendem comprovar de que modo esta contribuiu para o aumento de sintomas depressivos. Não se podendo, no entanto, afirmar que existe uma relação direta entre a doença e a pandemia.

Com esta dissertação pretendo analisar a relação da depressão com as redes sociais, referindo alguns estudos realizados, bem como criando classificadores automáticos recorrendo a técnicas de aprendizagem automática para detetar a depressão quer a nível de uma publicação textual quer ao nível do histórico do utilizador.

1.1 Motivação

Cada vez mais as redes sociais funcionam como um *escape* para as situações do quotidiano sendo utilizadas diariamente. No entanto, esta utilização em demasia pode provocar consequências negativas que são prejudiciais à saúde mental. Esta dependência acontece essencialmente nos jovens, que passam muitas horas *online* em prol do convívio presencial com os amigos. Sendo que existem várias consequências já conhecidas, como a dificuldade em adormecer, a procura de aprovação pelos outros e a procura da perfeição. Todos estes fatores podem em conjunto e prolongadamente resultar num surgimento de depressão [6].

Tendo a noção dos perigos existentes, é necessário a criação de técnicas de deteção de comportamentos e de situações que possam desencadear doenças do foro psicológico, de modo a minimizar os efeitos das redes sociais nos seres humanos.

Com o surgimento da pandemia e em especial com o confinamento/distanciamento social, as pessoas sentiram a necessidade de utilizar formas de comunicação virtuais. No entanto, conhecendo os perigos, isso pode significar que mais pessoas ficam susceptíveis à negatividade, o que pode originar um aumento de problemas mentais, devido à sua má utilização. Deste modo, é possível questionarmos se a utilização das redes é a melhor forma de contrariar positivamente a situação pandémica em que vivemos.

Se por um lado resolve temas como o isolamento, permitindo o contacto e a segurança, por outro, este meio de comunicação acarreta efeitos negativos, tais como, a disponibilização de notícias negativas frequentes; a publicação de conteúdos com o intuito de serem aprovados pelos outros através de gostos ou comentários positivos [70]; a sensação de FOMO (*Fear of missing out*), ou seja, o facto de visualizar alguém a fazer determinada atividade (como por exemplo, um café entre amigos) cria um sentimento desagradável e uma necessidade de criar algo semelhante para se satisfazer.

Todos estes pontos negativos, podem contribuir para o surgimento de doenças psíquicas, como a depressão.

Como podemos perceber, as redes sociais tanto podem ter pontos positivos como negativos, dependendo sempre de vários fatores e variando de pessoa para pessoa. Deste modo,

uma determinada situação pode provocar comportamentos diferentes.

Este tema da saúde mental começou a ser mais discutido desde que a pandemia surgiu, devido ao aumento de casos de pessoas com sintomas psicológicos. No entanto, não se consegue provar a relação direta da depressão com o Covid-19.

Devido a todos os pontos referidos anteriormente, é necessário criar métodos de análise dos conteúdos escritos pelos utilizadores nas redes sociais, de modo a encontrar padrões nos utilizadores depressivos, para que os mesmos possam servir como base na criação de um classificador automático.

1.2 Objetivos e Questões de Investigação

O *Twitter* consiste numa rede social que permite a comunicação entre várias pessoas, trocando mensagens com apenas 280 caracteres, denominados *tweets*. Os utilizadores utilizam-no para partilhar os seus pensamentos sobre determinados assuntos atuais assim como o seu estado de espírito. Segundo o estudo denominado *#StatusOfMind* da *Royal Society for Public Health* [54], esta é a rede com impacto mais positivo na sociedade. Na Figura 1.1 é possível constatar, que os efeitos mais negativos do *Twitter* são ansiedade, depressão, sono, *bullying* e FOMO e os efeitos positivos são auto expressão e identidade própria.

Por sua vez, o *Reddit* é uma rede social onde se pode discutir sobre assuntos variados sendo que cada *forum* de discussão denomina-se *subreddit*. Desde inícios de 2020, que esta ferramenta tem vindo a contribuir para as alterações negativas na saúde mental, devido à existência de notícias constantes sobre o Covid-19. Na Figura 1.2 é possível observar que 57,6% dos utilizadores desta rede referem que a saúde mental piorou.

O principal objetivo desta dissertação é detetar automaticamente a depressão em duas redes sociais distintas, *Twitter* e *Reddit*, considerando um *post* (denominado *tweet* no *Twitter*) por utilizador ou analisando o seu histórico, recorrendo aos comentários no *Reddit*.

Em relação ao Covid-19, apenas pretende-se fazer uma análise bibliográfica, sendo que as informações obtidas vão constar no Capítulo 2.

Com este trabalho pretende-se responder às seguintes questões de investigação:

1. A deteção da depressão é mais fiável considerando apenas um *post* ou olhando para o histórico de um utilizador?
2. Quais as *features* mais importantes nos *posts* dos utilizadores depressivos?
3. As palavras negativas servem para caraterizar um utilizador como depressivo?
4. Aplicando técnicas de variação de utilizadores é possível melhorar os resultados em termos de precisão, cobertura e medida f?




Figura 1.1: Impacto da saúde mental na rede social *Twitter* [54]

1.3 Metodologia

Para que sejam detetados sinais depressivos em utilizadores das redes sociais é necessário a definição de um modelo de aprendizagem automática que deve ser treinado e posteriormente testado para que, ao receber como entrada um conjunto de *posts* de um utilizador específico, consiga indicar se estamos perante um utilizador depressivo ou não. Para se poder analisar a viabilidade do modelo construído é necessário partir de um *dataset* já anotado. Deste modo, vão ser realizadas duas experiências distintas que permitem demonstrar a deteção da depressão quer ao nível de um *post* como considerando o histórico de um determinado utilizador.

De modo a analisar a depressão ao nível do histórico (*Reddit*), tal como apresentado na Figura 1.3, foi utilizado o *dataset* do RSDD (*Reddit Self-reported Depression Diagnosis*) que foi introduzido no artigo *Depression and Self-Harm Risk Assessment in Online Forums* [79] e que serviu como termo de comparação na obtenção dos resultados. No entanto, comparativamente ao modelo utilizado no artigo que recorre a redes neuronais, foram utilizados




Figura 1.2: Alterações na saúde mental por cada rede social influenciadas pelas notícias do Covid-19 [20]

modelos mais clássicos e validado se é possível obter resultados semelhantes.

Em relação à detecção a nível de um *post* (*Twitter*), foi utilizado o *dataset* do CLPYSCHE 2021 [11, 39] (consiste num *workshop* que reúne pesquisadores de linguagem computacional com profissionais na área da psicologia) e construído um dicionário com palavras provenientes de fontes distintas que estejam relacionadas com a depressão. Igualmente foram utilizados vários léxicos bem como obtidas as palavras negativas, recorrendo à biblioteca TextBlob², para se calcular as seguintes métricas: positivos, falsos positivos bem como a cobertura e a precisão positiva. Por fim foram aplicadas as técnicas de aprendizagem automática SVC Sigmoid Kernel, SVM (máquinas de vetor de suporte) [36] e Naive Bayes [35] e comparados resultados. Este processo é apresentado na Figura 1.4.

1.4 Estrutura do Documento

Este documento está estruturado da seguinte forma: o Capítulo 2 relata os fundamentos desta dissertação numa ótica de depressão, redes sociais, a relação dos mesmos e a influência do Covid-19 nos sintomas depressivos. O Capítulo 3 descreve o trabalho relacionado começando por uma visão cognitiva da depressão e finalizando com os artigos relacionados com a detecção automática. O Capítulo 4 refere as experiências realizadas nesta dissertação tanto a nível de um *post* como considerando o histórico do utilizador. O Capítulo 5 expõe as conclusões finais bem como as ideias de trabalho futuro.

²<https://textblob.readthedocs.io/en/dev/>

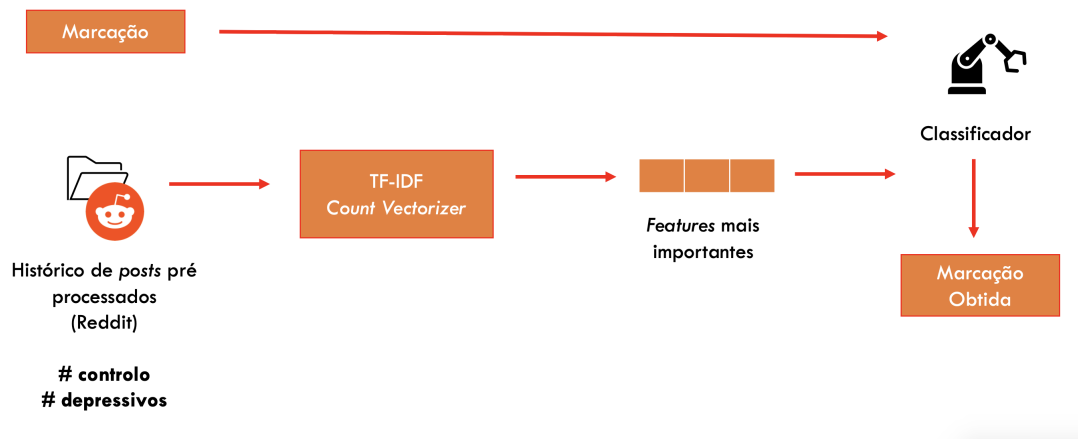


Figura 1.3: Experiência efetuada com os *posts* da rede social *Reddit*




Figura 1.4: Experiências efetuadas com os *posts* da rede social *Twitter*

Depressão e Redes Sociais

2

Neste capítulo são apresentados os fundamentos que sustentam esta dissertação. Na Seção 2.1 são revelados dados estatísticos relacionados com a depressão e com a utilização das redes sociais. De seguida, são referidos alguns estudos que pretendem abordar a influência das redes sociais nesta doença. Por último, são referidas investigações internacionais e nacionais que foram realizadas com o intuito de comprovar a influência da pandemia no surgimento de sintomas depressivos.

2.1 Depressão e Saúde Mental

A saúde mental é um dos assuntos mais abordados nos dias de hoje, sendo estimado que em cada cem pessoas, trinta possam vir a sofrer de problemas de saúde deste tipo e doze tenham um nível de gravidade maior [1]. Esta está relacionada com a capacidade de lidar positivamente com as adversidades, adaptação a mudanças, resolução de conflitos emocionais, definição de projetos de vida e com a sensação de bem estar físico e psíquico, quer com o próprio quer na relação com os outros tais como: doenças psíquicas como a ansiedade e a depressão, dependências, perturbações mentais como a esquizofrenia e demências. A Figura 2.1 apresenta a evolução do número de casos (entre 2006 e 2016) em Portugal para os três tipos de doenças mentais mais comuns: ansiedade, depressão e demência. Como se pode observar, existe uma proporção maior de pessoas com depressão (em 2016 foram 9,32) em relação às outras patologias.

A depressão é uma das doenças que pode afetar a saúde mental e que se caracteriza por um sentimento de tristeza, de autoestima baixa a longo prazo e que pode ser originado devido ao aumento da pobreza, do desemprego e de acontecimentos marcantes (como a morte de um familiar ou fins de relacionamentos), bem como traumas na infância ou *stress* [62].

Esta doença pode estar relacionada com a incapacidade ao nível laboral, levando ao aumento de baixas e de reformas antecipadas [59].

Segundo um estudo do *Europe Depression Association*, realizado em 2012 em vários países da Europa, um em cada dez colaboradores ausentou-se do trabalho devido à doença. Esta corresponde, em média, a trinta e seis dias anuais de trabalho perdidos. No mesmo foi




Figura 2.1: Evolução da proporção de casos nas doenças mentais mais comuns em Portugal Continental: depressão, demência e ansiedade [60]

mencionado que, um em cada quatro colaboradores não informa os chefes da sua condição de saúde devido ao medo de serem incompreendidos e, conseqüentemente, perderem o seu local de trabalho, sendo que um em cada três chefes não tem formas de lidar com a situação [8].

O suicídio é uma das consequências mais graves da depressão, representando 1,5% das mortes em todo o mundo, sendo que em 2015 foram estimados 788.000 casos com destaque nas faixas etárias dos 15 aos 29 anos [58]. Contrariamente, Portugal tem a maior taxa de suicídios na população mais idosa e do género masculino, devido à solidão e a doenças crónicas.

Normalmente as pessoas que praticam ou tem a vontade de o praticar tem uma doença mental grave, sendo que, caso o diagnóstico fosse efetuado atempadamente e atribuído o respetivo tratamento, poderia ser evitado. Contudo, a maior parte dos diagnósticos são feitos tardiamente ou o tratamento aplicado não é o adequado à situação.

2.1.1 Dados

Segundo dados da Organização Mundial de Saúde, em 2015, mais de 322 milhões de pessoas sofreram da doença, sendo nas regiões do Pacífico Ocidental e em África que mais se manifestaram [71].

A níveis mundiais esta doença afeta mais o género feminino do que masculino, bem como as idades mais adultas (55 aos 74 anos). No entanto, as faixas etárias mais baixas também são afetadas, mas em menor número.

Na Figura 2.2 é apresentado o números de casos de depressão pelas várias regiões da OMS. Como se pode observar, as regiões que têm maior número é a Ásia e o Pacífico, havendo mais oscilações ao longo do tempo.




Figura 2.2: Evolução dos casos de depressão desde 1990 até 2019 por região da OMS [25]

2.1.2 Tipos de Depressão

Para ser considerado depressão, os sintomas associados à doença (como perda de apetite ou alteração no sono, fadiga, dificuldade de concentração, indecisão, pensamentos de suicídio ou sentimentos de inutilidade e desespero), devem-se prolongar durante períodos seguidos.

Existem duas categorias:

1. **Depressão Maior:** é caracterizada pelo sentimento de vazio, falta de interesse pelas atividades rotineiras, cansaço físico e psicológico, insónias, angústia e tristeza sem motivo. Esses sintomas devem manter-se pelo menos durante duas semanas, manifestando-se em episódios. Este tipo está associado a uma das causas de incapacidade. Pode ser classificado de acordo com a sua gravidade e duração.
2. **Distímia:** é caracterizada por sintomas menos evidentes permitindo que a pessoa continue a efetuar as atividades normais e a trabalhar. Sendo dificilmente detetada e tornando-se crónica, pode evoluir para episódios de depressão maior (depressão dupla). Embora sejam sintomas ligeiros, a pessoa fica muito afetada tendo pouca energia e dificuldade de concentração, podendo prejudicar o desempenho profissional ou escolar. Afeta aproximadamente 3 a 6% da população em geral com destaque no género feminino [57].

2.1.3 Prevenção

Devido ao facto dos episódios se poderem desenvolver em qualquer momento da vida, é necessário aplicar medidas de prevenção a faixas etárias e a grupos alvos específicos. Em relação às faixas etárias, a prevenção deve-se focar nas crianças e jovens, durante os seus anos de formação; mães jovens em risco de depressão pós parto; idosos. Tendo em conta os fatores de risco que se dividem em biológicos, psicológicos e sociais, devem ser criados grupos alvo com mais do que um fator, devido ao facto de existir maior probabilidade de desenvolver a doença. Alguns dos fatores estão associados à existência de fatores hereditários de transtornos mentais, à violência infantil (como *bullying* e abusos), à exclusão social e doenças crónicas.

A OMS tem definido várias abordagens para a prevenção porque os tratamentos existentes só conseguem reduzir a doença em cerca de 34%.

Uma das abordagens passa por implementar programas de prevenção tanto nos sistemas de saúde como em escolas, locais de trabalho e lares.

Existem três tipos de prevenção definidos pelas OMS:

1. Prevenção Universal: foco na população em geral, promovendo positividade e capacidade mental para lidar com os problemas.
2. Prevenção Seletiva: dirigida a pessoas com vários fatores de risco.
3. Prevenção Indicada: dirigida a pessoas que tem sintomas depressivos sem um diagnóstico declarado, promovendo a autoestima.

A prevenção deve-se realizar cara-a-cara ou recorrendo às novas tecnologias. Também podem ser realizadas intercaladas. Presencialmente deve consistir em quatro ou oito sessões individuais ou em grupo, recorrendo a enfermeiros, psicólogos, entre outros; ou disponibilizando ferramentas de auto ajuda na *Internet*.

Aplicando estas abordagens consegue-se reduzir em 15%-35% o grau de incidência da doença. No entanto deve ser possível reduzir para 50% em abordagens nos lares de idosos recorrendo a técnicas de auto ajuda, vigilância e apoio de um médico para medicação, caso necessário [73].

2.1.4 Tratamento

A depressão pode ser tratada com vários medicamentos (como antidepressivos e antipsicóticos) e recorrendo a psicoterapia. Nos casos de depressão maior devem ser combinados. A psicoterapia pode ser realizada presencial de modo individual ou em grupo.

Segundo dados do Eurobarómetro e da DGS, as pessoas optam por cuidados primários para se tratarem em vez dos cuidados especializados. Na Figura 2.3 é possível verificar

que a maior parte dos entrevistados quer de Portugal quer da União Europeia recorreram a médicos de clínica geral (17%) em vez de psiquiatras (3%) ou psicólogos (2%). De notar que 78% dos entrevistados não recorreram a nenhum médico.

QD4. In the last 12 months, did you seek help from a professional because of a psychological or emotional problem? (IF YES) Indicate who in the following list.




Figura 2.3: Percentagem de entrevistados que recorreram a profissionais de saúde devido a problemas mentais - Eurobarómetro [69]

No entanto, nada garante que os médicos de clínica geral tenham conhecimentos suficientes para aplicar um tratamento eficaz. Deste modo, a OMS propõe que exista um trabalho conjunto entre estas duas áreas.

Para além dos tratamentos convencionais, existem outras formas de tratamento alternativo, tais como:

1. Fototerapia: utilizada no transtorno depressivo maior com tendência sazonal. A luz branca ajuda a melhorar o humor e consequentemente os sintomas da doença.
2. Acunpuntura, meditação e alguns suplementos.
3. Fazer exercício físico trinta minutos, duas a cinco vezes por semana.

Por mais que exista uma diversidade de tratamentos, apenas 34,5% das pessoas com a doença são tratadas. Na Tabela 2.1 é possível verificar que apenas 35,3%, em média, recorreram a médicos durante o primeiro ano das perturbações depressivas. Em relação à depressão maior, 37,4% recorreram a médicos, no entanto só foram tratados 4 anos após

os seus sintomas. Já em relação à distímia, decorreu menos tempo entre a deteção dos sintomas e o devido tratamento (3 anos).

Segundo a OMS, apenas um quarto dos doentes recebe tratamento e só 10% tem tratamento adequado.

NOSOLOGIA	INTERVALO SINTOMAS/ TRATAMENTO (anos)	MÉDICO NO 1º ANO %
PERTURBAÇÕES DEPRESSIVAS	5 (média do grupo)	35,3 (média do grupo)
Depressão maior	4	37,4
Bipolares	6	27,1
Distímias	3	37,5
PERTURBAÇÕES ANSIOSAS	23 (média do grupo)	12,7 (média do grupo)
Fobias sociais	18	7,5
Ansiedade generalizada	3	34,3
Pânico	2	45,8
ÁLCOOL	29 (média do grupo)	2,1 (média do grupo)
Abuso	29	3
Abuso/Dependência	21	4,3

Fonte – Portugal: Saúde Mental em números-2014. DGS/PNSM⁸

Tabela 2.1: Tratamento das perturbações psíquicas em Portugal em 2014 [58]

Estes números baixos podem estar associados à deteção tardia ou ao facto de as pessoas serem relutantes ao tratamento bem como ao estigma envolvido.

2.2 Redes Sociais

Cada vez mais pessoas utilizam as redes sociais em todo o mundo. O *Facebook* é a rede social mais utilizada, representando 45% da população mundial. Na Figura 2.4 é possível visualizar o *top* de redes sociais mais utilizadas entre 2004 e 2019. De referir que a rede social que se encontra no topo é o *Facebook*, sendo a única com mais de dois biliões, seguindo-se o *YouTube* e o *Whatsapp*.

Em 2020, comparativamente a 2008, a percentagem de utilizadores de redes sociais aumentou para 79% [15], o que pode estar relacionado com a situação pandémica. O tempo dispendido nas redes também tem vindo a aumentar sendo que, as faixas etárias mais predominantes são dos 18 aos 29 anos. Na Figura 2.5 é possível verificar que, desde 2012 até 2016, houve uma subida acentuada do número de horas dispendidas nas redes, tendo-se verificado, a partir desse ano, uma subida mais lenta. Na Figura 2.6 constata-se que a faixa etária que mais utiliza as redes sociais é a dos 18 aos 29 anos (88%), seguindo-se a dos 30 aos 49 anos (78%).

2.3 Depressão e Redes Sociais

Existem vários estudos e artigos que referem a influência das redes nos problemas mentais, especialmente depressão e ansiedade.




Figura 2.4: Evolução do número de pessoas que utilizam as redes sociais desde 2004 até 2019 [12]

Daily Time Spent on Social Media

Average h:mm spent engaging with/connected to social networks during a typical day




Figura 2.5: Evolução do tempo gasto nas redes sociais desde 2012 até 2019 [27]




Figura 2.6: Utilização das redes sociais por faixa etária [15]

Segundo o estudo desenvolvido na *Royal Society for Public Health*, denominado *#StatusOfMind* [54], as redes sociais podem provocar efeitos negativos e os mesmos estão associados à má utilização. O mesmo conclui que existem cinco redes sociais com maior impacto negativo na saúde mental: *Instagram*, *Snapchat*, *Facebook*, *Twitter* e *YouTube* (Figura 2.7).

Também o artigo *The Atlantic* [6] refere que a taxa de depressão tem vindo a aumentar, principalmente na geração Z, e que isso se deve ao facto de os mesmos optarem por relações virtuais em prol de comunicações físicas e de se isolarem da vida em sociedade para dispenderem mais do que duas horas diárias nos seus dispositivos eletrónicos. O número de tempo dispendido nas redes também pode estar associado a maiores probabilidades de se sentir infeliz e nalguns casos levar a pensamentos suicidas. Segundo este artigo, existem mais raparigas com depressão (50%) em relação aos rapazes e é este género que está mais associado a casos de suicídio. Este artigo mostra também que as atividades que eram consideradas normais, tais como socializar com os amigos/encontros, tem vindo a sofrer uma quebra, ao contrário dos sentimentos de solidão e dificuldades de adormecer que têm aumentado (Figuras 2.8 e 2.9).

Em Abril de 2011 surgiu um fenómeno controverso criado pela *American Academic of Pediatrics*, denominado *Facebook depression* [49], que defendia que a utilização das redes sociais, pelas crianças e adolescentes, pode fazer com que os mesmos fiquem susceptíveis a situações de *cyberbullying* bem como a pressão *online*, provocando baixa autoestima e consequentemente ansiedade ou depressão.

Os fatores que podem desencadear a depressão são os seguintes: aprovação pelo ou-

tro através do número de gostos ou comentários, várias notícias negativas, a sensação de FOMO (medo de estar a perder algo), a ideia errada que as redes sociais correspondem à perfeição, entre outros.




Figura 2.7: Resultados obtidos no estudo #StatusOfMind representando as cinco redes sociais com maior impacto na saúde mental [54]

2.4 A influência do Covid-19 nos sintomas depressivos

A influência do Covid-19 nos sintomas depressivos tem vindo a ser estudado por vários institutos de investigação.

Segundo um estudo publicado na revista Jama [18], o número de sintomas depressivos aumentou durante a pandemia nos EUA comparativamente aos anos anteriores (27,8%). Esse aumento deveu-se a inúmeros fatores como a situação financeira, a limitação da socialização bem como perdas de emprego. Na Figura 2.10, é possível observar, um aumento de adultos com depressão durante o Covid-19, comparativamente à pré pandemia. No entanto, a maior parte dos sintomas detetados são do grau menos severo.

No Brasil também foi realizado um estudo [28] considerando apenas pessoas que já tinham sido diagnosticadas com Covid-19, de modo a analisar as consequências da doença na saúde mental. Segundo essa pesquisa, chegou-se à conclusão que a quarentena também pode ter contribuído para o aumento de depressão nesses pacientes (26,2%).




Figura 2.8: Evolução da taxa de jovens da Geração Z que se sentem mais sozinhos, desde 1991 até 2015 [6]

Outro estudo [81] efetuado pela Universidade *Penn State* (nos EUA) e pela Universidade de *Jinan* (na China) e publicado na revista científica *Computers in Human Behavior* concluiu que a utilização em demasia das redes sociais mais a existência de inúmeras notícias sobre o Covid-19 pode criar períodos de incerteza e consequentemente afetar a saúde mental.

O tema da saúde mental associado à pandemia tem sido analisado pela OMS uma vez que, o isolamento pode provocar solidão e ansiedade.

Segundo estudo de *Workana* [77], que consistia na análise da depressão em pessoas que, passaram a trabalhar em casa em regime de teletrabalho, 43,8% dos trabalhadores apresenta problemas do foro mental: 24% dificuldade de concentração, 13,2% ansiedade, 5,8% solidão e 0,8% depressão.

Na Figura 2.11 são apresentadas as respostas obtidas a um questionário efetuado pela *Mastercard* [40]. Como se pode verificar, as pessoas começaram a dar mais importância à saúde mental (62 pessoas), ao tempo que passam com os amigos (60 pessoas) e a relaxarem (59 pessoas).

Os adolescentes são a classe etária mais afetada com a pandemia, sendo referido que, os jovens passaram a conviver mais através de videochamadas e/ou chamadas, em vez de encontros físicos com amigos, bem como a utilização das redes sociais também aumentou (56%) [9].

Na Figura 2.12 é possível observar os efeitos da pandemia na saúde. Considerando os dados reportados pelos pais dos adolescentes, é possível perceber que afeta mais raparigas do que rapazes e que são a ansiedade e a depressão os mais relatados.

Segundo dados da US Census Bureau [10], houve um aumento de sintomas de ansiedade e de depressão nos EUA na altura da pandemia (Figura 2.13). Igualmente indica que




Figura 2.9: Evolução do tempo dispendido pelos jovens da geração Z no convívio presencial [6]

esse aumento está associado a jovens adultos (provocados por fechos de universidades, transição para teletrabalho ou aulas remotas e perda de emprego ou diminuição de salários) e a mulheres com filhos pequenos (associado ao fecho de escolas e creches).

Segundo o estudo da KFF, as mulheres desenvolvem sintomas depressivos, devido ao facto de trabalharem imensas horas em conjunto com as atividades domésticas, podendo levar a esgotamentos. Também os profissionais de saúde apresentaram elevadas taxas de depressão, devido ao facto de correrem riscos, por não poderem trabalhar em casa e muitas vezes não conseguirem cumprir o distanciamento social provocando medo e insegurança [30].

As incertezas em relação ao futuro também podem desencadear sintomas de depressão principalmente nos estudantes universitários. Desde a pandemia, devido ao fecho de universidades, começou-se a notar um aumento de sintomas depressivos (Figura 2.14) nos estudantes, devido ao medo de serem contagiados (25,8%) ou de contagiarem alguém (64,4%), ao cansaço extremo provocados por longas horas no computador.

Em relação a Portugal o cenário não difere muito, comparando com o resto do mundo. Segundo um estudo realizado pelo SNS, 25% dos participantes mostraram sintomas depressivos, ansiedade ou depressão. Os medos reportados pelos participantes foram os seguintes: não saber quando vai existir uma vacina eficaz, medo de uma crise económica, medo de não conseguirem recuperar rendimentos e da sua vida nunca mais voltar a ser a mesma [61].

No entanto, também existem estudos que indicam não existir uma relação direta do Covid-19 com a saúde mental (Universidade de Amesterdão) [52], bem como outros que defendem que as redes sociais contribuíram para o combate da solidão bem como diminuíram a ansiedade ou o *stress* (Figura 2.15).

Figure. Depression Symptoms in US Adults Before and During the Coronavirus Disease 2019 (COVID-19) Pandemic




Figura 2.10: Figura comparativa de depressão em adultos, antes e durante a pandemia [22]

Pesquisa da Mastercard mostra como a saúde mental ganhou relevância

Pessoas foram perguntadas sobre quais atividades se tornaram essenciais em comparação com antes da pandemia.




Figura 2.11: Atividades mais investidas durante a pandemia [19]





Figura 2.12: Efeitos da pandemia nos jovens [9]

COVID'S MENTAL STRESS

The percentage of people experiencing symptoms of depression and anxiety has surged amid the COVID-19 pandemic, data from nationally representative surveys show.

■ Before pandemic ■ During pandemic

UK adults reporting symptoms of depression



US adults reporting symptoms of anxiety or depression



©nature

Figura 2.13: Taxa de adultos nos Estado Unidos com sintomas depressivos declarado, antes e durante a pandemia [45]

Percentage of Students Reporting Mental Health and Substance Abuse Issues, Fall 2019 v. Spring 2020




Figura 2.14: Percentagem de estudantes que reportaram problemas psíquicos, antes e durante a pandemia [55]

The therapeutic side of social media

% in the UK/U.S. who agree with the following statements

Over the past 2 months
social media has helped me...

● All internet users

● Digital detoxers*

...feel less lonely

57%

64%

...feel less anxious or stressed

48%

55%

*Digital detoxers are defined as internet users who have tracked their screen time or set limits for certain apps in the past month

Question: To what extent do you agree or disagree with these statements? (Strongly agree, Somewhat agree)

Source: GlobalWebIndex May 2020 **Base:** 2,345 UK/U.S. internet users who use public social channels aged 16-64; 278 UK/U.S. digital detoxers who use public social channels aged 16-64

Figura 2.15: Percentagem de pessoas que se sentiram mais sozinhas, ansiosas ou depressivas durante a pandemia [68]

2.5 Conclusões

Em suma, tem-se notado um aumento de casos de depressão e de utilizadores das redes sociais ao longo do tempo. Tendo em conta alguns artigos, as redes sociais podem ser um dos fatores responsáveis pelo surgimento de problemas psicológicos e consequentemente maior taxa de suicídio. No entanto, não se encontra uma prova evidente que o aumento do número de casos de depressão no mundo esteja de facto relacionado com a utilização das redes sociais. Se por um lado existem estudos que pretendem demonstrar a negatividade das redes sociais, por outro, o facto da sua existência na altura da pandemia serviu para minimizar o isolamento e permitir a comunicação entre as pessoas de um modo mais seguro. Deste modo, torna-se necessário considerar outros fatores, como a pessoa e/ou situação envolvida.

Com o surgimento do Covid-19, também se tem notado um aumento de pessoas com sintomas depressivos, no entanto, mais uma vez, não se consegue provar a relação direta da depressão com a pandemia. Segundo diversos estudos, o aumento de sintomas depressivos deve-se às inseguranças, ao medo de contagiar e/ou ser contagiado, à alteração de rotinas, à perda de emprego, à diminuição de salários, ao fecho de universidades, entre outros.

3

Trabalho Relacionado

Neste capítulo, são apresentadas as pesquisas relacionadas com o tema desta dissertação. Na Secção 3.1 são apresentados artigos que analisam a depressão numa perspetiva das ciências cognitivas. Uma vez que esta está associada ao foro psicológico, tornou-se relevante analisar esta doença partindo duma visão da psicologia, de modo a compreender o funcionamento do sistema cognitivo e a relação do mesmo com a doença, antes de se analisar artigos relacionados com a deteção automática na Secção 3.2. Esta secção é dividida em pré-processamento e métodos automáticos de deteção.

3.1 Depressão Nas Ciências Cognitivas

De modo a compreender a depressão numa perspetiva cognitiva, foram analisados artigos que referem diferentes modelos.

Existem autores que utilizam o modelo circumplexo de Russel [53] que apenas se foca em duas dimensões *valence* e *arousal* e outros autores que analisam a depressão distribuída num contexto tridimensional (Pleasure - Arousal - Dominance) mais conhecida como o modelo PAD ou VAD [42].

O *Pleasure* está associado ao sentimento optimista (+P) ou pessimista (-P), a *Arousal* ao nível de atividade física ou mental e o *Dominance* à capacidade de controlo das ações.

Xu, De Boeck e Strunk [78] consideram que a depressão se localiza no lado esquerdo do modelo (Figura 3.1), estando associada a valores de *valence* positivos e *arousal* negativos (modelo circumplexo de Russel). Por sua vez, Mehrabian [42] refere que a depressão se associa a menores valores de *pleasure*, *arousal* e *dominance* do que a ansiedade (modelo tridimensional). Ou seja, a depressão e a ansiedade tem maior predominância de sentimentos negativos (-P), com menor capacidade de controlo das ações (-D), no entanto, a depressão tem menos níveis de atividade (-A) do que a ansiedade (+A).

Como se pode observar na Figura 3.1, a depressão está associada a um conjunto de emoções básicas - desespero (*hopeless*), infelicidade (*unhappy*), inutilidade (*worthless*), fracasso (*failure*), desamparo (*helpless*), tristeza (*sad*), desânimo (*depressed*) - que são divergentes das emoções básicas que dizem respeito à ansiedade. De salientar que a emoção desânimo não serve por si só para a caracterização da doença, tal como referido, uma vez




Figura 3.1: Modelo circunplexo de Russel - lado esquerdo representa a depressão [78]

que uma pessoa pode aparentar sinais depressivos em qualquer momento, no entanto, isso não quer dizer que esteja de facto com a doença.

3.2 Deteção Automática da Depressão

Em relação à deteção da depressão de modo automático, foram analisados vários artigos que recorreram a diferentes metodologias.

A maior parte dos artigos analisados extraem os *posts* usando a API do *twitter*, pelo que se torna necessário efetuar marcações manuais/automáticas, de modo a ser possível a comparação dos resultados obtidos pelos classificadores criados.

Mowery et al. [44] define palavras associadas a cada sintoma depressivo (cor lilás da Figura 3.2)¹ e a cada estímulo psicossocial que provoca *stress* (cor roxa da Figura 3.2)² recorrendo ao LIWC (lista de palavras categorizadas gramaticalmente e psicologicamente), a psicólogos (denominado SAD) e ao CLPYSCHE, que consiste numa lista de utilizadores com diagnóstico declarado.

Kumar, Sharma e Arora [32] focam-se na depressão ansiosa que se caracteriza por pessoas que tem sintomas de ansiedade associados à depressão. De modo a compreender se o *tweet* analisado se relaciona com a depressão ansiosa, foi criado um vetor com as seguintes variáveis: *w* (validação da palavra no léxico), *t* (indicação de dois ou mais *tweets* entre as

¹Esta lista de sintomas foi retirada do Diagnostic and Statistical Manual of Mental Disorders, Edition 5 [3]

²Esta lista de estímulos psicossociais foi retirada do Axis IV of the Diagnostic and Statistical Manual of Mental Disorders, Edition IV (DSM-IV) [2]

	SAD		CLPsych
Depressed Mood	<i>cry, crying, sad, depressed, tired, me, emoticon_sad, heart,</i>	<i>i, rt</i>	<i>diagnosed, depression, was, severe, clinical, cut, since, doctor</i>
Anhedonia	<i>alcoholic, exactly, dunno, ive, music, plans, age, career, must, changed</i>		
Weight change or change in appetite	<i>weight, appetite, hungry, crisps, diet, lost, food, eaten, eat, days</i>		<i>fat, possibilities, hinting, terrifying, anorexic, now, regret, abundance, hospitalize, pounds</i>
Disturbed sleep	<i>sleep, wide, insomniac, awake, deprivation, tired, up, night, deprived</i>	<i>insomnia,</i>	<i>think, because, depression, mostly, yeah, only, sleeping, went, better</i>
Psychomotor agitation or retardation	<i>restless, getting, couldn, beating, started, idk, ache, quite, breath, okaay</i>		
Fatigue or loss of energy	<i>you, af, im, die, sad, alone, bed,</i>	<i>tired, so</i>	<i>being, exhausted, tonight, sick, had, mental</i>
Feelings of worthlessness or excessive guilt	<i>loser, feel, failure, many, cost, tagged, guilt</i>	<i>i, worthless, guilty</i>	<i>effort, mostly, makeup, myself, insecure, convinced, deserve</i>
Diminished ability to think or concentrate	<i>concentrate, focus, can, homework, indecisive, trouble, curse, focussss, productive, realy</i>		
Recurrent thoughts of death, suicidal ideation	<i>die, myself, kill, i, please, if, tired, alone</i>	<i>suicide, want,</i>	<i>suicidal, life, hinting, plans, so, committing, saved, goodbye</i>
Problems with expected life course ..	<i>dreams, hike, becoming, somethings, positive, visualising, pursue, remind, calendared, basically</i>		<i>didn, mugged, professional, failure, literally, become, footballer, lost, everything, reckon</i>
Problems with primary support group	<i>you, me, my, love, u, hurt, miss, tired, mom, friends</i>		<i>fml, seriously, did, leave, nerve, best, special, hateyou, worst, favor, divorce</i>
Problems related to the social environment	<i>alone, lonely, i, friends, people, flirting, talk, feel, want, you</i>		<i>me, suuuuccckssss, careless, co, http, unwanted, genuinely, fuckyou, potential, brightly</i>
Educational problems	<i>school, fail, test, teacher, failing, class, studying, exam, failed, college</i>		
Occupational problems	<i>fired, work, unemployment, hired, hunter, hrs, mammoth, pizza, uugh, publicrelation</i>		<i>any, rules, jobs, so, suicide, office, annoyed, manual, employ, qualifications</i>
Housing problems	<i>homeless, niggas, since, safe, smoke, able, afford, wonderihng, truth, degrees</i>		
Economic problems	<i>broke, money, being, car, breakfast, serving, clue, outcome, happily, boxes</i>		
Problems with access to healthcare			
Problems related to legal system/crime	<i>grandma, such, second, buzz, found, cops, guilty, killl, murder, degree</i>		
Other psychosocial & environmental stressors	<i>album, plotted, fiction, brothers, tough, innocent, ruinedforever, ste, popularr, motherfuckers</i>		
Weather	<i>weather, snow, rain, fuckin, day, cold, buzz, grey, wet, raining</i>		
Media	<i>watching, songs, listening, cried, song, makes watched, crying, sad, news</i>		

Figura 3.2: Palavras associadas a cada sintoma depressivo e estímulo psicossocial causador de stress, extraídas de anotações manuais e de bibliotecas.

0h e as 6h), *f* (frequência de *tweets* numa hora), *s* (marcação quando existem mais de 25% de *tweets* com polaridade negativa), *c* (variação de *tweets* positivos e negativos).

Segundo estes autores, este tipo de depressão caracteriza-se pela existência de *tweets* escritos entre as 0h e as 6h devido aos pacientes sofrerem de insónias, pela escrita de mais do que três *tweets* numa determinada hora e pela variância de picos de optimismo e pessimismo com maior predominância de *tweets* negativos.

Stephen e Prabu [65] criam um *corpus* extraíndo *tweets* de palavras chave selecionadas (*abuse, anxiety, addict, addiction* e *bullying*) de vários utilizadores do *twitter*, sendo os mesmos agrupados por dia, de modo a ser possível analisar a variação da depressão.

Hasan, Rundensteiner e Agu [24] criam um léxico que pretende inferir estados emocionais denominado EMOTEX através da extração de *tweets* recorrendo a palavras chave, correspondentes às vinte e oito emoções básicas do modelo circumplexo de Russel, com a junção das palavras do WordNet. Os autores optaram por esse modo de extração uma vez que, segundo os mesmos, as *hashtags* utilizadas podem auxiliar na agrupação por determinada emoção.

3.2.1 Pré-processamento dos Dados

De modo a remover algumas palavras ou símbolos que possam ser irrelevantes ao classificador, é necessário pré-processar os dados tendo em conta várias técnicas de processamento da língua como a remoção de números, URL, símbolos especiais, *stop words* e pontuação, bem como a utilização da tokenização, do *stemming* [32], a identificação da negação e o *part-of-speech tagging* [38].

Outra das técnicas referidas são a remoção de *tweets* que utilizem no mesmo os *emojis* “feliz” e “triste” [24] e a utilização de léxicos de sentimento como *Spanish Sentiment Lexicon* e *Spanish SentiCon Lexicon* [38].

3.2.2 Detecção de Depressão

Kumar, Sharma e Arora [32] e Hasan, Rundensteiner e Agu [24] utilizam classificadores supervisionados como o *Naive Bayes*, o *Gradient Boosting* e o *Random Forest* de modo a calcular a taxa de acerto e a medida f. Kumar, Sharma e Arora [32] recorre à utilização de marcadores indicativos da presença de ansiedade (linguísticos) e relativos à existência de negatividade e variação de polaridade (semânticos) e considera o tempo e frequência dos *tweets* na construção do seu classificador. Por sua vez Hasan, Rundensteiner e Agu [24] faz uma seleção de *features* tendo em conta várias categorias: unigramas, *emojis*, pontuação e negação, uma vez que os mesmos podem ser representativos de uma emoção específica.

Por outro lado, Mowery et al. [44] determinam o coeficiente de correlação de Pearson [75] para validarem a correlação entre dois sintomas depressivos com os estímulos psicossociais considerando quatro categorias distintas e Stephen e Prabu [65] calculam a magnitude da depressão utilizando o pacote de R para extração de sentimentos - *syuzhet* [29] e avaliam o sentimento comparando três léxicos AFFIN [47], BING [26] e NRC [43].

3.3 Conclusões

Em termos de conclusões obtidas a partir da análise dos artigos, os autores referem a dificuldade encontrada na deteção de *tweets* associados à doença, sendo que as maiores percentagens estão associadas a *posts* que referem a palavra depressão. Os sintomas mais associados à doença são o humor deprimido, a fadiga e a perda de energia. É necessário ter em conta mais do que uma palavra na deteção, uma vez que uma só palavra pode ser utilizada em contextos distintos [44]. Foram encontradas situações de depressão em horários ou dias específicos e especialmente entre as 0h e as 6h, uma vez que estas pessoas sofrem problemas de insónias [32]. A atividade nas redes sociais é mais ativa ao fim de semana do que aos dias de semana uma vez que existe menor atividade social. No que diz respeito à linguagem utilizada foram encontrados os seguintes aspetos:

- Maior utilização do pronome pessoal “eu” em utilizadores depressivos, contrariamente aos pronomes pessoais “nós”, “vós” pois estas pessoas encontram-se em isolamento social;
- Utilização de mais verbos, advérbios e pronomes devido ao facto de a linguagem ser focada em ações [38];
- Muitos adjetivos na forma feminina, o que significa que a maior parte das pessoas que sofrem de depressão são do sexo feminino;
- Linguagem emocional com foco negativo, uma vez que as pessoas que sofrem desta doença são pessimistas com tudo o que os rodeia.

Em termos de limitações, são referidos problemas no diagnóstico formal de depressão uma vez que, depois de se terem detetado automaticamente os casos é necessário validar manualmente se de facto correspondem a casos reais, que devem ser avaliados e consequentemente tratados. Estas técnicas, no entanto, podem servir como uma forma de compreensão dos pacientes que estão num centro de reabilitação bem como auxiliar os médicos no entendimento do comportamento de uma pessoa específica, considerando a sua “atividade online” [65]. Outra das limitações referidas é o facto de existirem leis de privacidade de dados que impedem o acesso a perfis privados, impedindo deste modo a deteção de depressão para esses utilizadores [38]. O mesmo autor refere que, devido ao facto de existirem várias redes sociais, o *Twitter* pode não representar a população toda, limitando a análise.

Como trabalho futuro, os autores propõem adicionar novas palavras chave na construção do léxico associado à depressão de modo a melhorarem os seus resultados, quanto à precisão e cobertura [44], testar os resultados em termos geográficos, faixa etária e profissão [32], não limitar a deteção da depressão à rede social *Twitter* [65], efetuar novas pesquisas de modo a examinar outros tipos de depressão e estudar padrões de comportamento em diferentes contextos, ver a relação da depressão com a sazonalidade, de modo a ser possível monitorizar a atividade nas redes sociais [38] e a integração de outros dados relevantes como o sono, a atividade física e a informação alimentar dos utilizadores.

Deteção Automática da Depressão

4

Neste capítulo, são apresentadas as experiências realizadas no âmbito desta dissertação. De modo a se comparar a deteção da depressão, considerando apenas um *post* de um utilizador com o histórico completo, foram realizadas duas experiências distintas.

Na primeira experiência foi utilizado um *dataset* que apenas contém uma linha por utilizador com a respetiva marcação de depressão. Posteriormente foram aplicadas técnicas de pré-processamento e utilizados vários léxicos. Por último, foram treinados um classificador Naive Bayes e um SVM.

Na segunda experiência, recorreu-se ao *dataset* do RSDD que contem a marcação dos utilizadores como depressivos ou de controlo, tendo em conta o seu histórico. Tendo como base o artigo *Depression and Self-Harm Risk Assessment in Online Forums* [79], pretende-se aplicar métodos de aprendizagem automática clássicos e comparar os resultados obtidos com os da experiência.

4.1 Experiências ao Nível do *Post*

Inicialmente é apresentado o *dataset* utilizado na experiência assim como as técnicas de pré-processamento utilizadas (Secção 4.1.1 e 4.1.2). De seguida, são referidas as metodologias e algoritmos utilizados para a construção dos dicionários (Secção 4.1.3). Por último é apresentada a análise de resultados (Secção 4.1.4).

4.1.1 *Dataset*

Considerou-se o *dataset* utilizado no CLPYSCH 2021 [11, 39] que consiste num conjunto de *posts* escritos no *Twitter* por utilizadores no ano de 2018, tal como se pode visualizar na Tabela 4.1.

Este *dataset* é composto por *tweets* escritos em inglês, tendo o mínimo de 1 palavra, a média de 16 palavras e o máximo de 61 palavras por *post*.

Cada linha corresponde a um *tweet* escrito por um utilizador.

Unnamed: 0			tweet	target
3195	3195	May the new year abound in H's: Health, Hope, ...		0
3196	3196	It is not a beautiful day as usual.		1
3197	3197	Compact Metal Leaf Grinder with Four Layers p...		0
3198	3198	First Christmas in YEARS that I have to work. ...		0
3199	3199	It's okay sus. Let that hurt go 🥺 * that's me ...		0

Tabela 4.1: Exemplo de *tweets* com marcação de depressão

Dos 843 *posts* marcados com *target* 1 (depressivos), o mínimo de palavras é 3, com o *tweet* - Depression sucks #getHelp, o máximo é 61 e a média é 18.

Dos 2357 *posts* marcados com *target* 0 (controlo), o mínimo de palavras é 1, o máximo é 54 e a média é 16.

4.1.2 Pré-Processamento

Como se pode visualizar na Figura 4.1, os utilizadores dos *posts* utilizam *emojis*, pontuação, bem como outros caracteres especiais, como *hashtags*, números e URLs. Sendo que, excluindo os *emojis*, os restantes não trazem valor acrescentado no momento de criação de um classificador.

Deste modo, utilizando a biblioteca NLTK [48] foi efetuada a tokenização, o *pos-tagging* e a lematização, bem como removidas *stop words*, pontuação e caracteres especiais já referidos. Uma vez que se utilizam *emojis* foi necessário utilizar uma biblioteca de conversão (EMOT) [66].

4.1.3 Metodologia

Nesta secção são apresentadas as metodologias utilizadas nesta experiência. Inicialmente é referido o algoritmo criado recorrendo ao léxico NRC VAD, bem como a utilização dos léxicos SDD [50], Choudhury [14] e Pedesis [21]. Posteriormente é referido o processo de criação do dicionário com a junção das palavras caracterizadoras da depressão. De seguida, utilizando a biblioteca TextBlob, é apresentada a lista de palavras com polaridade negativa dos *tweets*. Por fim, apresenta-se o trabalho relativo aos classificadores Naive Bayes e SVM.

4.1.3.1 NRC VAD

Para esta experiência foi criado um léxico que definiu cada dimensão (*Valence*, *Arousal*, *Dominance*) como positiva ou negativa (somando as três dimensões), bem como marcadas as palavras em que a premissa - o valor do *arousal* é superior ao do *dominance* e do *valence* - se aplicava.

Tendo como base o artigo de Xu, De Boeck e Strunk [78], a depressão é caracterizada por valores negativos ou positivos de *valence*, valores negativos de *arousal* e valores negativos de *dominance* e, uma vez que o léxico NRC VAD não contém valores negativos, foi necessário encontrar um valor que definisse a negatividade da dimensão. Deste modo, selecionou-se a palavra *depression* do léxico e observou-se que o *arousal* era de 0,52 e que as outras dimensões tinham valores inferiores a esta.

Foi criado o algoritmo apresentado, separado em duas experiências distintas.

Por cada palavra do *tweet*:

- Se $V \leq 0,52$ então $-V$, caso contrário V
- Se $A \leq 0,52$ então $-A$, caso contrário A
- Se $D \leq 0,52$ então D , caso contrário D
- Obtenção do $VAD = V + A + D$
- Marcação das palavras em que a premissa referida anteriormente se verifica ($A > V$, $A > D$)
- O primeiro léxico criado contém 1935 palavras em que o $V(+/-)$, $A(-)$, $D(-)$ e que foram marcadas de acordo com a premissa referida.
- O segundo léxico criado foca-se nas palavras em que o $A(-)$ e o $D(-)$. Tendo sido obtidas 7795 palavras.

4.1.3.2 SDD, Choudhury e Pedesis

Considerando os léxicos SDD (Social Depression Detection), Choudhury e Pedesis, foram marcados como depressivos os *tweets* que continham palavras existentes nesses léxicos.

O léxico SDD contém uma lista de palavras relacionadas com a depressão, distribuídas por tópicos diferentes que dizem respeito a sintomas referidos no PHQ-9, que foram obtidas utilizando técnicas de LDA, tal como referido no artigo *Semi-Supervised Approach to Monitoring Clinical Depressive Symptoms in Social Media* [80]. Contem 160 palavras agrupadas por 10 tópicos diferentes.

O léxico Choudhury foi criado com base num conjunto de *posts* de utilizadores do Twitter. Estando distribuído por quatro dimensões distintas (sintomas, revelação, tratamento e relações) e representado em unigramas. Este foi referido no artigo *Predicting Depression via Social Media* [14] e contém 1870 palavras.

Por sua vez, o léxico Pedesis seleciona as palavras que tem uma maior relação com a depressão. Este contém 9584 palavras e foi referido no artigo *Proactive screening for depression through metaphorical and automatic text analysis* [46].

4.1.3.3 Dicionário de depressão

Nesta experiência, foi criado um dicionário de palavras relacionadas com depressão, recorrendo a 12 fontes distintas:

- Fonte 1: Palavras destacadas no artigo *Understanding Depressive Symptoms and Psychosocial Stressors on Twitter: A Corpus-Based Study* [44] apresentadas na Figura 3.2.
- Fonte 2: Palavras consideradas no artigo *Detecting Signs of Depression in Tweets in Spanish: Behavioral and Linguistic Analysis* [38] como indicativas de depressão.
- Fonte 3: Palavras relacionadas com depressão retiradas do Thesaurus pesquisando pela palavra *depression* [67].
- Fonte 4: Palavras obtidas na lista de vocabulário emocional, criada pela Karla McLaren, que pretende classificar as emoções em três graus (suave, médio e intenso). Este vocabulário divide-se nos seguintes grupos: raiva, apatia e ódio; vergonha e culpa; medo, ansiedade e pânico; inveja; felicidade e alegria; tristeza, pesar e depressão; depressão e impulsos suicidas. Para a seleção obteve-se as palavras a partir do grupo tristeza, pesar e depressão que correspondem ao vocabulário associado a sintomas depressivos [41].
- Fonte 5: Palavras obtidas do DSM - Questionário de depressão para adultos [4], questionário *Parent Guardian of Child Age 6-17* e especificadores para transtornos depressivos do DSM versão V [3].
- Fonte 6: Palavras provenientes do léxico de psiquiatria e termos de saúde mental [51].
- Fonte 7: Palavras consideradas no questionário do HANDSTM: *The Harvard Department of Psychiatry National Depression Screening Day Scale* que consiste num conjunto de dez questões para identificar pessoas com sintomas recentes de depressão [23].
- Fonte 8: Palavras referidas no questionário de PHQ-9 que contém perguntas sobre a depressão que devem ser pontuadas de zero a três, tendo em conta os nove critérios do DSM-IV [64]. Este questionário foi desenvolvido por Dr. Robert J. Spitzer, Dr. Janet B.W. Williams, Dr. Kurt Kroenke no artigo *The PHQ-9 Validity of a Brief Depression Severity Measure* [31].
- Fonte 9: Palavras obtidas no IDS-QIDS que permite avaliar a gravidade dos sintomas depressivos [17]. Neste caso, considerou-se apenas os nove domínios analisados no questionário. Este formulário foi proposto pelo Dr. Augustus John Rush, Jr no artigo *An Evaluation of the Quick Inventory of Depressive Symptomatology and the Hamilton Rating Scale for Depression: A Sequenced Treatment Alternatives to Relieve Depression Trial Report* [56].

- Fonte 10: Palavras do questionário BRFSS (*Behavioral Risk Factor Surveillance System*) 2018 que é efetuado telefonicamente para pessoas que residem nos Estados Unidos, com o intuito de compreender comportamentos de risco e que é agrupado por vários módulos relacionadas com a saúde [16]. Para a seleção de palavras foi considerado apenas o módulo 9 - *Depression and Anxiety*.
- Fonte 11: Palavras retiradas da definição de depressão indicada pela Associação Americana de Psiquiatria [5].
- Fonte 12: Palavras referidas no BDI (*Beck Depression Inventory*), que foi desenvolvido por Aaron T. Beck, referido no artigo *An Inventory for Measuring Depression* [7] e que consiste num conjunto de 21 perguntas que mede a gravidade da depressão.

4.1.4 Análise de Resultados

Nesta secção são apresentados resultados obtidos através das experiências: algoritmo do NRC VAD e léxicos, dicionários e palavras negativas ou caracterizadoras de *tweets* depressivos.

4.1.4.1 Algoritmo do NRC VAD e léxicos

Na Tabela 4.2 são apresentados os resultados obtidos em cada léxico, tendo em conta as seguintes métricas: número de *posts* marcadas como depressivos (1), e não depressivos (0), falsos positivos/negativos e precisões/coberturas positivas. A primeira coluna corresponde aos resultados da experiência realizada com o léxico NRC VAD selecionando apenas as palavras que cumprem as premissas: $A > D$ e $A > V$ e que tem as dimensões *arousal* e *dominance* negativos (ver Secção 4.1.3.1). A segunda coluna corresponde aos resultados da experiência selecionando as palavras do léxico NRC VAD que apenas cumprem a premissa $A > D$ e $A > V$. As outras colunas correspondem aos resultados obtidos pelos léxicos, já referidos, SDD, Choudhury e Pedesis. A cobertura e precisão positiva dizem respeito à classe depressiva.

Métrica	NCR VAD (1º)	NCR VAD(2º)	SDD	Choudhury	Pedesis
Depressivos	189	700	78	643	760
Controlo	1992	532	2244	806	391
Falsos Positivos	365	1825	113	1551	1966
Falsos Negativos	654	143	765	200	83
Precisão Positiva	34,1%	27,7%	40,8%	29,3%	27,9%
Cobertura Positiva	22,4%	83,0%	9,3%	76,3%	90,1%

Tabela 4.2: Resultados obtidos por léxico. A experiência 1 do NRC VAD tem em conta A e D negativos e $A > D$ e $A > V$ e a experiência 2 tem em conta apenas A e D negativos.

Comparando os resultados dos léxicos analisados, o SDD apresentou maior taxa de precisão positiva (40,8%) e o Pedesis apresentou 90,1% de cobertura positiva.

Através da Figura 4.1 podemos concluir que muitos dos *posts* obtidos contêm palavras que não são diretamente relacionadas com a depressão, como por exemplo, *overthinking*, *anything*, *keen*. No entanto, se fossem analisadas numa frase como um todo, com várias palavras relacionadas, poderiam ter sido marcadas como depressivas. Do mesmo modo, existem *posts*, marcados originalmente como não depressivos, mas que ao utilizar o algoritmo foram marcados como depressivos.

Falsos Negativos - corresponde aos casos em que eram depressivos no post original (1) mas foram marcado como controlo (0)

- ([‘Im’, ‘keep’, ‘overthinking’, ‘pictwittercomeEHOTtoCXWD’], 1, 0)
- ([‘anything’, ‘find’, ‘peer’, ‘balcony’, ‘see’, ‘bloody’, ‘ground’], 1, 0)
- ([‘Not’, ‘keen’, ‘Xmas’, ‘Chin’, ‘remember’, ‘hype’, ‘day’, ‘ ’], 1, 0)
- ([‘Hope’, ‘everyone’, ‘New’, ‘Years’, ‘tonight’, ‘mine’, ‘gonna’, ‘shit’], 1, 0)
- ([‘Ive’, ‘sleep’, ‘well’, ‘part’, ‘day’, ‘away’], 1, 0)

Falsos Positivos - corresponde aos casos em que eram controlo no post original (0) mas foram marcado como depressivo (1)

- ([‘nothing’, ‘well’, ‘go’, ‘weather’, ‘grim’, ‘home’], 0, 1)
- ([‘want’, ‘spend’, ‘Christmas’, ‘w’, ‘husband’, ‘mommy’, ‘none’, ‘Ill’, ‘drink’, ‘day’], 0, 1)
- ([‘chickmcgee’, ‘ThatJoshArnold’, ‘Not’, ‘game’, ‘Inuit’, ‘woman’, ‘play’, ‘first’, ‘laugh’, ‘breathless’, ‘loss’], 0, 1)
- ([‘time’, ‘fart’, ‘jump’, ‘fear’, ‘yass’], 0, 1)
- ([‘till’, ‘stop’, ‘feel’, ‘hate’, 0, 1)

Figura 4.1: Extração de falsos negativos e positivos obtidos na primeira experiência

Relativamente aos resultados obtidos, considerando apenas as palavras em que A e D são negativos, é possível verificar que algumas delas não foram detetadas no algoritmo criado, tais como: *cry*, *hate*, *depress*. Contudo existem *posts* que continham palavras negativas como *suicide* e que no algoritmo criado foram marcadas como depressivas, mas no entanto, analisando o contexto da frase podem estar associadas a um dado informativo (Figura 4.2).

Quanto aos resultados obtidos com o léxico SDD, é possível verificar que existem erros ortográficos nalguns *posts*, o que leva a que essas palavras não sejam consideradas. Como por exemplo, a palavra *depwession* que deveria ser *depression* deixaria de ser um falso negativo. Outra palavra associada a um exemplo de falso positivo, é o *fatigue*. Esta foi

Falsos Negativos - corresponde aos casos em que eram depressivos no post original (1) mas foram marcado como controlo (0)

- ([‘really’, ‘feel’, ‘cry’, ‘right’], 1, 0)
- ([‘hate’, ‘crush’, ‘love’], 1, 0)
- ([‘Ive’, ‘realise’, ‘admit’, ‘suffer’, ‘best’], 1, 0)
- ([‘Im’, ‘depress’, ‘fault’, ‘changing’], 1, 0)
- ([‘feel’, ‘mentally’, ‘right’, ‘Dunno’, ‘Feel’, ‘completely’, ‘control’], 1, 0)

Falsos Positivos - corresponde aos casos em que eram controlo no post original (0) mas foram marcado como depressivo (1)

- ([‘Wow’, ‘bit’, ‘Freddie’, ‘bit’, ‘lol’, ‘NinjaWarriorAU’], 0, 1)
- ([‘Jamba’, ‘Juice’, ‘mall’, ‘anymore’], 0, 1)
- ([‘Heard’, ‘Willy’, ‘Nelson’, ‘sing’, ‘Scientist’, ‘thought’, ‘So’, ‘THIS’, ‘Then’, ‘discover’, ‘cover’, ‘Coldplay’], 0, 1)
- ([‘Suicide’, ‘year’, ‘peak’, ‘pictwittercomORXfwCDCG’], 0, 1)
- ([‘party’, ‘tattoo’, ‘dodie’, ‘become’, ‘cheer’, ‘song’], 0, 1)

Figura 4.2: Extração de falsos negativos e positivos obtidos na segunda experiência

marcada como depressiva uma vez que o léxico utilizado contem palavras que caracterizam a doença tal como a fadiga. O exemplo referido refere-se a uma situação de uma pessoa que indica que está com fadiga, mas que não está diretamente relacionado com depressão. Ou seja, a análise palavra a palavra faz com que muitos dos *posts* possam ter sido marcados por conterem palavras que estão relacionadas com a doença, mas deste modo perde-se o contexto da frase. Este exemplo pode ser verificado na Figura 4.3

Na Figura 4.4, que corresponde a uma extração dos falsos positivos e negativos de utilizações do léxico Choudhury, é possível verificar que foi marcado como depressivo um *post* que contém a palavra *pain*. No entanto, analisando as palavras que compõem a frase, encontram-se palavras positivas (como por exemplo, *love*, *happiness* e *smile*) o que, como referido no trabalho relacionado, os utilizadores depressivos focam-se na utilização de palavras negativas, logo não corresponde a um *post* de depressão.

4.1.4.2 Dicionário da depressão

Relativamente aos resultados obtidos na Tabela 4.3, a fonte 10 teve melhores resultados de precisão positiva (72,2%) e a fonte 1 obteve melhores resultados de cobertura (18%) e 153 positivos.

Falsos Negativos - corresponde aos casos em que eram depressivos no post original (1) mas foram marcado como controlo (0)

- ([‘Fighting’, ‘exboyfriend’, ‘Me’, ‘need’, ‘space’, ‘Him’, ‘Maybe’, ‘take’, ‘med’, ‘Me’, ‘hahahahahaha’], 1, 0)
- ([‘Only’, ‘difference’, ‘hurt’, ‘lead’, ‘fracture’, ‘GG’, ‘N’], 1, 0)
- ([‘hurt’, ‘Im’, ‘practically’, ‘Im’, ‘anything’, ‘else’], 1, 0)
- ([‘Be’, ‘vewy’, ‘Im’, ‘hunt’, ‘self’, ‘esteem’, ‘depwession’, ‘gun’], 1, 0)
- ([‘Had’, ‘way’, ‘home’, ‘dinner’], 1, 0)

Falsos Positivos - corresponde aos casos em que eram controlo no post original (0) mas foram marcado como depressivo (1)

- ([‘adventure’, ‘start’, ‘get’, ‘bored’, ‘restless’, ‘need’, ‘buddy’, ‘someone’, ‘like’, ‘thing’], 0, 1)
- ([‘sad’, ‘depression’, ‘Get’, ‘help’, ‘Get’], 0, 1)
- ([‘know’, ‘yesterday’, ‘today’, ‘im’, ‘fatigue’], 0, 1)
- ([‘Honestly’, ‘consider’, ‘grab’, ‘cider’, ‘put’, ‘Forest’, ‘Gump’, ‘ugly’, ‘cry’], 0, 1)
- ([‘people’, ‘preoccupy’, ‘thought’, ‘worthlessness’, ‘guilt’, ‘helplessness’, ‘hopelessness’], 0, 1)

Figura 4.3: Extração de falsos negativos e positivos obtidos com o cruzamento com o léxico SDD

Fonte	Depressivo	Controlo	Falsos Positivos	Falsos Negativos	Precisão Positiva	Cobertura Positiva
1	153	2200	157	690	49%	18%
2	97	2288	69	746	58%	11,5%
3	22	2338	19	821	53,6%	2,6%
4	30	2338	19	813	61,2%	3,6%
5	0	2357	0	843	0%	0%
6	10	2347	10	833	50%	11,8%
7	12	2334	13	831	48%	1,4%
8	0	2357	0	843	0%	0%
9	1	2353	4	842	20%	0,1%
10	8	2354	3	835	72,2%	0,9%
11	11	2345	12	832	47,8%	1,3%
12	40	2329	28	803	58,8%	4,7%

Tabela 4.3: Resultados obtidos por fonte.

Analisando os resultados por fonte, é possível reparar que apenas uma pequena parte dos *posts*, foi corretamente marcado como depressivos (primeira coluna da Figura 4.5) existindo ainda uma quantidade alta de falsos positivos e negativos. Estes valores relativamente

Falsos Negativos - corresponde aos casos em que eram depressivos no post original (1) mas foram marcado como controlo (0)

- (['Not', 'keen', 'Xmas', 'Chin', 'remember', 'hype', 'day', ' '], 1, 0)
- (['always', 'reason'], 1, 0)
- (['hour', 'day', 'Im', 'die'], 1, 0)
- (['Going', 'go'], 1, 0)
- (['everything', 'nothing'], 1, 0)

Falsos Positivos - corresponde aos casos em que eram controlo no post original (0) mas foram marcado como depressivo (1)

- (['edutopia', 'way', 'see', 'whats', 'go', 'classroom', 'leadup', 'awesomeness'], 0, 1)
- (['BCFCCCommunity', 'Jnr', 'blue', 'parent', 'Meeting', 'lot', 'info', 'give', 'cheer', 'development', 'baileyu', 'excited'], 0, 1)
- (['Hello', 'gamers', 'Im', 'tell', 'Nazi'], 0, 1)
- (['Two', 'legged', 'sample', 'humor', 'comedy'], 0, 1)
- (['MINE', 'baby', 'headache', 'love', 'smile', 'frown', 'pain', 'happiness', 'everything'], 0, 1)

Figura 4.4: Extração de falsos negativos e positivos obtidos com o cruzamento com o léxico Choudhury

baixos podem ser justificados devido ao facto de os utilizadores depressivos utilizarem mais verbos e pronomes, tal como referido no Capítulo 3. No entanto, o dicionário criado, uma vez que provêm de dicionários e de questionários, contêm maioritariamente nomes e adjetivos, o que pode justificar esses resultados.

Considerando a junção das palavras de todas as fontes, é possível verificar que o valor de positivos aumentou para 183 bem como a cobertura positiva passou para 21,7% (Tabela 4.4).

Fonte	Depressivo	Controlo	Falsos Positivos	Falsos Negativos	Precisão Positiva	Cobertura Positiva
Todas	183	2166	191	660	48,9%	21,7%

Tabela 4.4: Resultados obtidos com a junção de todas as palavras do dicionário.

Analisando os resultados obtidos através da junção de palavras do dicionário, é possível constatar que as palavras *cruel* e *life* separadas não tem significado, no entanto, juntas podem indicar que a pessoa está deprimida. A palavra *killme*, devido ao facto de possuir um pronome pessoal agregado, impediu que esta tivesse conotação depressiva (Figura 4.5).

Falsos Negativos - corresponde aos casos em que eram depressivos no post original (1) mas foram marcado como controlo (0)

- ([‘life’, ‘cruel’], 1, 0)
- ([‘HOESHIKO’, ‘use’, ‘fowl’, ‘sorry’, ‘Im’, ‘disappointment’, ‘please’, ‘killme’], 1, 0)
- ([‘Given’, ‘answer’, ‘matter’, ‘bottom’, ‘Christian’, ‘friend’], 1, 0)
- ([‘go’, ‘betrayal’, ‘disappointment’, ‘life’, ‘realise’, ‘keep’, ‘people’, ‘foot’, ‘away’], 1, 0)
- ([‘Sometimes’, ‘want’, ‘make’, ‘thing’, ‘well’, ‘nothing’, ‘apologize’, ‘deserve’, ‘apology’, ‘heart’, ‘smell’, ‘desperation’], 1, 0)

Falsos Positivos - corresponde aos casos em que eram controlo no post original (0) mas foram marcado como depressivo (1)

- ([‘Vin’, ‘Diesel’, ‘pretty’, ‘cool’, ‘see’, ‘movie’, ‘Riddick’, ‘Pitch’, ‘Black’, ‘work’, ‘something’, ‘smiles’], 0, 1)
- ([‘Infact’, ‘keenly’, ‘observe’, ‘religion’, ‘hater’, ‘community’, ‘hater’, ‘currently’, ‘depression’, ‘attack’], 0, 1)
- ([‘Best’, ‘anxiety’, ‘depression’, ‘fix’, ‘eye’, ‘pup’, ‘world’, ‘feel’, ‘time’, ‘receiving’, ‘pictwittercomP1CsKUyGj’], 0, 1)
- ([‘Loneliness’, ‘feed’, ‘depression’, ‘depression’, ‘trigger’, ‘loneliness’, ‘thing’, ‘remember’, ‘cycle’, ‘step’, ‘help’, ‘change’, ‘Therapy’, ‘help’, ‘identify’, ‘step’, ‘pictwittercomTxRnnlCQ’], 0, 1)
- ([‘deal’, ‘depression’, ‘remember’, ‘talk’, ‘close’, ‘person’, ‘trust’, ‘know’, ‘speak’, ‘Ill’, ‘try’, ‘help’, ‘much’, ‘hear’, ‘problem’], 0, 1)

Figura 4.5: Extração de falsos negativos e positivos obtidos com a junção de palavras do léxico criado

4.1.4.3 Palavras negativas e caracterizadoras de *tweets* depressivos

Na tentativa de melhorar os resultados, decidiu-se obter as trinta palavras mais utilizadas nos *tweets* depressivos. Na Figura 4.6, é possível verificar que as palavras que mais se utilizam não se conseguem relacionar com a depressão, sendo essencialmente pronomes pessoais e verbos (*feel*, *cry*, *take*, *make*, *go*, *want*).

Uma vez que não foi possível encontrar novas palavras para o dicionário, optou-se por uma abordagem diferente. Foram obtidas as palavras com polaridade negativa através da biblioteca *TextBlob*.

Na Figura 4.7 é possível verificar que as palavras negativas nos *tweets*, contrariamente à abordagem anterior, podem ter uma relação com a depressão. Observam-se, por exemplo as palavras com maior utilização: *depress*, *fuck*, *hate*, *lonely*, *shit*, *sad*, *ill*, *disappointment* e *mean*.




Figura 4.6: Top das trinta palavras mais utilizadas em *tweets* depressivos

Antes de adicionar as novas palavras, foi validado se já existiam no dicionário criado. Foi possível concluir que a maior parte das palavras negativas não eram encontradas. As palavras existentes corresponderam a *lonely, sad, crying, fail, tired, failure, empty, black, down*.




Figura 4.7: Palavras caracterizadas com polaridade negativa nos *tweets*

Adicionando essas novas palavras ao dicionário, os resultados foram ligeiramente melhores o que dá a entender que as palavras negativas servem para definir um *post* como depressivo. Na Tabela 4.5 é possível visualizar os resultados considerando as métricas referidas anteriormente. Nesta experiência foi possível marcar corretamente 351 *posts* depressivos num total de 843 *posts* correspondentes a utilizadores depressivos.

Fonte	Depressivo	Controlo	Falsos Positivos	Falsos Negativos	Precisão Positiva	Cobertura Positiva
Novas Palavras	351	1959	398	492	46,8%	41,6%

Tabela 4.5: Resultados obtidos adicionando as palavras negativas

Após aplicadas as metodologias já referidas, decidiu-se utilizar modelos de aprendizagem automática para validar os resultados obtidos. Optou-se por seleccionar três classificadores clássicos recorrendo à biblioteca *sklearn* [63].

Analisado os resultados em termos de marcação dos *posts*, é possível validar que muitos dos *posts* que dizem respeito a utilizadores depressivos, não tem palavras caracterizadoras da doença, o que faz com que não consigam ser detetadas. Exemplo: «Can't believe I'm missing my favourite night» e «Today is my last day of cipralex». No caso do segundo *post*, é referido o nome de um medicamento, no entanto, as fontes utilizadas para a construção do dicionário não tiveram em conta a lista de medicamentos, logo não foi detetado.

Foi possível obter melhores resultados de taxa de acerto com o *SVC Sigmoid Kernel* (79%) seguido do *Naive Bayes* (78,7%) e do *SVM* (74,6%) considerando 80% de treino e 20% de teste.

4.2 Experiências ao Nível do Histórico do Utilizador

Nesta secção é apresentado o *dataset* utilizado na experiência bem como as técnicas de pré-processamento utilizadas (Secção 4.2.1 e 4.2.2). De seguida, são referidas as metodologias aplicadas (Secção 4.2.4) bem como a lista de *features* mais importantes obtidas (Secção 4.2.3). Por último é apresentada a análise de resultados.

4.2.1 Dataset

Foi utilizado o *dataset* RSDD (*Reddit Self-Reporting Depression Diagnosis*) que corresponde a um conjunto de *posts* escritos em inglês por utilizadores entre Janeiro e Outubro de 2016 na rede social *Reddit*. Estes estão ordenados cronologicamente, sendo 6.140 utilizadores depressivos e 71.258 utilizadores de controlo. Em média existem 969 *posts* por utilizador.

Para a experiência foi necessário remover os utilizadores que não tinham nenhuma marcação e considerados apenas os utilizadores de treino e teste.

Deste modo, foram considerados 3.070 utilizadores depressivos e 35.753 utilizadores de controlo (treino) e 3.070 utilizadores depressivos e 35.775 utilizadores de controlo (teste).

4.2.2 Pré-Processamento

Para o pré-processamento dos dados foram utilizadas as bibliotecas de NLTK de modo a remover *hashtags*, menções e imagem URLs, pontuações, *stop words*. Por último, aplicou-se o *stemmer* de Porter.

4.2.3 Features Mais Importantes

De modo a ser possível analisar as palavras que melhor caracterizam os utilizadores depressivos, considerando os primeiros e os últimos 1.500 *posts*, foram aplicados vários métodos estatísticos tanto considerando unigramas como bigramas.

Após obtidos os conjuntos utilizando a lei de Zipf [76], a harmonic CDF (*Cumulative distribution function*) [74] e o logaritmo de base 10, foi possível observar que os resultados que melhor caracterizam os utilizadores depressivos foram através do logaritmo de base 10, isto é, os resultados obtidos através da seguinte fórmula:

$$Features_{importantes} = \frac{\log_{10}(N_{Ocorrencias(Dep)}+1)}{\log_{10}(Total_{Dep})} - \frac{\log_{10}(N_{Ocorrencias(Controlo)}+1)}{\log_{10}(Total_{Controlo})}$$

Segundo os resultados obtidos nas duas experiências, foi possível encontrar mais palavras relacionadas com medicamentos para a depressão e ansiedade nos últimos 1.500 *posts* dos utilizadores comparando com os primeiros 1.500 *posts*. O que dá a entender que os utilizadores reportados como depressivos em análise, utilizaram palavras relacionadas com sintomas ou situações que possam estar na origem da doença como *suicidal, manic, psychosis, therapy, disorder, childfree, anorexia, emotional, abusive, hallucinations, relationship, hormones, empatetic, hospitalized, illness* e *anxiety*. Sendo que nos últimos *posts* já existe maior ocorrência de palavras relacionadas com tratamento ou medicação como *casualconversation, mindfulness, wordly, medications, meditation, prescribed, xanax* e *psychiatrist*.

4.2.4 Metodologias

De modo a determinar qual a metodologia mais adequada a aplicar ao modelo foram efetuados testes, utilizando o respetivo *dataset*, recorrendo ao CountVectorizer (transforma um conjunto de documentos numa matriz de contagem de termos) [33] e ao TfidfVectorizer (transforma um conjunto de documentos numa matriz aplicando o TF-IDF que consiste na multiplicação do número de vezes que a palavra aparece num documento com a frequência inversa da palavra num conjunto de documentos) [37], variando o número de *features* em unigramas, bigramas e trigramas e removendo o número de termos, cuja frequência é inferior (mínimo df) ou superior (máximo df) ao estabelecido para um modelo de *machine learning* SVC Linear.

Tal como se pode observar nas Figuras 4.8 e 4.9 a percentagem de taxa de acerto no Count Vectorizer apenas atingiu o máximo de 78,30%, o que comparativamente ao TF-IDF,

obteve valores de taxa de acerto menores. Deste modo, foram analisados os resultados do TF-IDF para que se possa escolher quais os parâmetros mais adequados. A experiência que permitiu obter melhores resultados foi o TF-IDF aplicando um mínimo df de 5 (ignorando os termos que aparecem em menos de 5 documentos) e um máximo df de 0,7 (ignorando os termos que aparecem em mais do que 70% dos documentos) para os bigramas (83,30%).




Figura 4.8: Resultados obtidos por Count Vectorizer variando o número de *features* e parâmetros.

Visualizando a Figura 4.9, o modelo obtém os melhores resultados a partir das 300.000 atingindo o pico nas 500.000 *features* para o TF-IDF com os parâmetros referidos anteriormente (linha azul do gráfico).

De tal modo que optou-se por utilizar o modelo de aprendizagem automática SVC (*Support Vector Classifier*) Linear (consiste em encontrar inicialmente dois vetores de suporte de modo a marcar o hiper plano ideal mais ajustado que categoriza em duas classes distintas) [34], recorrendo ao TF-IDF em bigramas, com 500.000 *features* e com o mínimo df de 5 e o máximo df de 0,7.

Após seleccionada a técnica de preparação de dados, e tendo como termo de comparação o artigo *Depression and Self-Harm Risk Assessment in Online Forums* [79], foram efetuadas experiências seleccionando os 400 ou 1.500 *posts* por utilizador tendo em conta os primeiros, os últimos ou seleccionando aleatoriamente.

Uma vez que o *dataset* contém utilizadores sem marcação de depressão que não são relevantes para o modelo, estes utilizadores foram removidos.

Sendo que os valores de cobertura para esta experiência (barra laranja), foram muito baixos comparativamente aos valores do artigo (Figura 4.10).

Deste modo, recorreu-se a duas técnicas para equilibrar os dados: *under sampling* (diminui o tamanho da classe com mais registos) [13] e *over sampling* (aumenta o tamanho da classe com menos registos) de modo a analisar se é possível obter melhores resultados.

Como se pode observar na Figura 4.10, aplicando uma técnica de *over sampling* (barra




Figura 4.9: Resultados obtidos utilizando TF-IDF variando o número de *features* e de parâmetros.

cinzenta), isto é, aumentando o número de utilizadores depressivos para o dobro, foi possível obter valores de cobertura mais aproximados do artigo (53%) considerando 400 *posts* aleatórios por utilizador (47,6%).




Figura 4.10: Resultados em termos de cobertura obtidos nas experiências (utilizando o modelo de TF-IDF com 500.000 *features*, mínimo *document frequency* 5 e máximo *document frequency* 0,7 e o modelo de aprendizagem automática SVC Linear), *over sampling* e *under sampling*.

Em relação aos 1.500 *posts*, o que obteve valores mais aproximados ao trabalho de referência (55%) foi os primeiros *posts* escritos pelos utilizadores (47,4%).

Ao aplicar o *under sampling*, isto é, reduzindo o número de utilizadores de controlo para

30.000, de modo, a existir menos discrepância entre os utilizadores, foi possível melhores resultados de cobertura para os 1.500 *posts* aleatórios, contudo, os restantes não foram melhores do que os obtidos com a técnica referida anteriormente.

Em relação às outras métricas, foi possível obter valores de precisão superiores aos do artigo em todas as experiências considerando 400 ou 1.500 *posts* por utilizador (Figura 4.11). Enquanto a medida *f*, apresentado na Figura 4.12, foi apenas superior ao do artigo para os primeiros 1.500 *posts* ou 400 *posts* aleatórios em todas as experiências. Para estas métricas, a variação do número de utilizadores não teve um impacto significativo nos resultados.




Figura 4.11: Resultados em termos de precisão obtidos nas experiências (utilizando o modelo de TF-IDF com 500.000 *features*, mínimo *document frequency* 5 e máximo *document frequency* 0,7 e o modelo de aprendizagem automática SVC Linear), *over sampling* e *under sampling*.

4.2.5 Análise de Resultados

O modelo que acertou na maior parte das classificações da classe depressiva, isto é com percentagens mais elevadas de precisão, foi o que recebeu como entrada 1.500 *posts* aleatórios do utilizador sem aplicação de técnicas de variação de utilizadores (90,6%). No entanto, este modelo não obteve as melhores taxas de cobertura. Sendo necessário reduzir o número de utilizadores de controlo, isto é, aplicando *under sampling*, para que os valores desta métrica sejam melhorados. No entanto, o valor de cobertura continuou baixo comparativamente ao do artigo. Aplicando *over sampling*, o melhor valor de cobertura foi conseguido considerando os últimos 1.500 *posts* dos utilizadores (48,5%). Em relação à medida *f*, a experiência com melhores resultados foi o *under sampling* considerando 1.500 *posts* aleatórios (62,5%).

Tendo em conta os resultados obtidos, o melhor modelo consiste em passar como entrada 1.500 *posts* por utilizador e seleccioná-los aleatoriamente, ou considerando apenas os




Figura 4.12: Resultados em termos da medida f obtidos nas experiências (utilizando o modelo de TF-IDF com 500.000 *features*, mínimo *document frequency* 5 e máximo *document frequency* 0,7 e o modelo de aprendizagem automática SVC Linear), *over sampling* e *under sampling*.

últimos 1.500 *posts*. Posteriormente os mesmos devem ser pré processados recorrendo ao TF-IDF com os parâmetros mínimo df 5 e máximo df 0,7. Caso se pretenda melhorar os resultados de cobertura é necessário aplicar técnicas de *over sampling*, uma vez que existem mais utilizadores de controlo comparativamente aos depressivos, de modo a balancear melhor o número de utilizadores.

4.3 Conclusões

Relativamente às questões de investigação, foi possível concluir que:

- Questão 1: A deteção a nível de um *post* de utilizador é menos fiável, do que analisando o histórico do mesmo. Uma vez que os sintomas da depressão se devem prolongar durante períodos seguidos e um *post* corresponde a um sentimento momentâneo, torna-se necessário analisar o perfil do utilizador considerando os *posts* escritos num determinado período.
- Questão 2: As *features* mais importantes, encontradas nos *posts* depressivos, dizem respeito a sintomas ou situações que possam estar na origem da doença bem como a tratamento ou medicação.
- Questão 3: Ao serem adicionadas as palavras negativas, obtidas através da biblioteca TextBlob, foi possível marcar mais *tweets* corretamente como depressivos.

- Questão 4: Aplicando técnicas de variação de utilizadores, como o *over sampling* e o *under sampling* foi possível obter resultados de cobertura mais aproximados aos do artigo. Contudo não teve grande relevância nas restantes métricas.

Conclusões e Trabalho Futuro

As redes sociais são um meio de comunicação onde as pessoas partilham os sentimentos e emoções, o que pode permitir a sua análise e consequentemente aplicar medidas de deteção da depressão. No entanto, os resultados obtidos tem de ser analisados cuidadosamente, uma vez que existe uma variedade enorme de palavras que podem ser utilizadas e que não estão diretamente relacionadas com a depressão.

A depressão é uma das doenças que mais afeta o mundo atual e que está associada a casos de incapacidade laboral e situações de suicídio. Esta não é facilmente diagnosticada por estar associada a vários sintomas relacionados com outras doenças, e também devido ao facto de as pessoas recorrerem tardiamente a médicos que, na maioria das vezes, não são especializados na área.

Existem vários estudos que pretendem comprovar a relação das redes sociais com as doenças mentais. O modo como as redes podem afetar ou não uma pessoa depende de vários fatores e pode manifestar-se de modos diferentes, dependendo se esta faz uma boa ou má utilização das redes.

Também existem trabalhos de investigação que pretendem relacionar a pandemia com os sintomas depressivos. Sendo comprovado que o Covid-19, devido ao isolamento social, a outros fatores como a situação financeira, o teletrabalho e o fecho de escolas e à incerteza em relação ao futuro, contribuiu para o aumento de casos de pessoas com estes sintomas.

Nesta dissertação foram efetuadas duas experiências distintas.

Numa primeira fase foi efetuada a deteção, recorrendo a um *dataset* que tinha a marcação de depressão por *post* de um utilizador, através de léxicos já existentes bem como criando um novo dicionário com palavras relacionadas com a doença.

A segunda experiência consistiu na utilização do *dataset* RSDD, que tinha a marcação de um utilizador depressivo por conjunto de *posts*, aplicando modelos clássicos de aprendizagem automática (SVC Linear com TF-IDF).

Com estas experiências foi possível concluir que, o facto de as pessoas quando estão depressivas não utilizarem palavras relacionadas com a depressão, optando por um vocabulário diversificado, torna difícil a deteção recorrendo a léxicos, uma vez que estes contêm apenas palavras caraterizadoras da doença. Na deteção palavra por palavra perde-se o

contexto da frase, o que permitiu que determinados *posts* fossem marcadas como depressivos só por conterem palavras caracterizadoras, mas se se analisasse a frase como um todo percebia-se que apenas se estava a constatar um facto.

No entanto, as pessoas que sofrem desta doença utilizam palavras negativas no seu vocabulário, o que justificou a melhoria de resultados adicionando essas mesmas palavras ao dicionário criado na experiência 1.

A análise ao nível de um *post* não é suficiente pois um *post* corresponde a um momento exato e uma pessoa pode indicar que está depressiva num dado momento mas não significa que esteja com a doença em questão.

Assim, a segunda experiência parece ser mais adequada, na medida em que, analisa um conjunto de *posts* por utilizador num determinado período, o que tal como indicado no trabalho relacionado, só pode ser considerado depressão se os sintomas se repetirem várias semanas seguidas.

Comparando os resultados com o trabalho usado como referência, foi possível concluir que as taxas de cobertura ficaram abaixo, no entanto, aplicando técnicas de variação de conjuntos da dados como *over sampling* ou *under sampling*, os resultados aproximaram-se um pouco mais. Por sua vez, os valores de precisão foram mais elevados.

Esta ferramenta permite detetar pessoas com princípios de depressão ou com indícios de suicídio, contudo estes resultados devem ser validados *a posteriori* por uma pessoa especializada na área da psicologia ou da psiquiatria. Caso fosse aplicada em contexto real, teria de ser num ambiente controlado, como por exemplo, centros de reabilitação ou centros psiquiátricos, em que houvesse acesso aos *posts* escritos pelos pacientes. Existem leis de privacidade que não permitem o acesso aos dados sem autorização dos utilizadores. Deste modo, a única forma seria analisar os mesmos, recorrendo ao anonimato, não sendo possível relacionar o conjunto de *posts* marcados como depressivos a uma pessoa específica. Outra limitação existente, é o facto de as pessoas estarem relutantes ao assunto, o que torna necessário a criação de abordagens para explicar que aquilo que andam a colocar nas redes sociais se relaciona com situações de doença mental.

De referir que não foi possível trabalhar os dados em contexto do Covid-19, tal como inicialmente previsto, sendo que a ideia pensada seria algo a fazer futuramente.

Como trabalho futuro e de forma a relacionar a pandemia com a depressão, é necessário extrair o histórico de vários utilizadores da rede social *Twitter* nos períodos pré e durante a pandemia de modo a que sejam utilizados no classificador que obteve os melhores resultados nesta dissertação.

Bibliografia

- [1] Associação de Apoio aos Doentes Depressivos e Bipolares. *O que é a saúde mental?* URL: <https://www.adeb.pt/pages/o-que-e-a-saude-mental> (acedido em 22/08/2021).
- [2] American Psychiatric Association. *Diagnostic and statistical manual of mental disorders DSM-IV*. URL: https://www.academia.edu/11886511/DSM-IV-TR._Diagnostic_and_statistical_manual_of_mental_disorders (acedido em 22/07/2021).
- [3] American Psychiatric Association. *Manual Diagnóstico e estatístico de transtornos mentais - DSM-5*. URL: https://dislex.co.pt/images/pdfs/DSM_V.pdf (acedido em 12/07/2021).
- [4] American Psychiatric Association. *Online Assessment Measures*. URL: <https://www.psychiatry.org/psychiatrists/practice/dsm/educational-resources/assessment-measures> (acedido em 20/07/2021).
- [5] American Psychiatric Association. *What is depression?* URL: <https://www.psychiatry.org/patients-families/depression/what-is-depression> (acedido em 22/06/2021).
- [6] The Atlantic. *Have Smartphones destroyed a generation?* URL: <https://www.theatlantic.com/magazine/archive/2017/09/has-the-smartphone-destroyed-a-generation/534198/> (acedido em 20/06/2021).
- [7] Aaron T Beck et al. "An inventory for measuring depression". Em: *Archives of general psychiatry* 4.6 (1961), pp. 561–571.
- [8] Bellanima. *Impact of Depression in the Workplace in Europe*. URL: <https://www.bellanima.ro/impact-depression-workplace-europe/> (acedido em 10/08/2021).
- [9] Health Blog. *National Poll: Pandemic Negatively Impacted Teens' Mental Health*. URL: <https://healthblog.uofmhealth.org/childrens-health/national-poll-pandemic-negatively-impacted-teens-mental-health> (acedido em 22/07/2021).
- [10] US Census Bureau. *Coronavirus (COVID-19) Pandemic*. URL: <https://www.census.gov/topics/preparedness/events/pandemics/covid-19.html> (acedido em 02/10/2021).
- [11] CLPsych. *The Workshop on Computational Linguistics and Clinical Psychology*. URL: <https://clpsych.org> (acedido em 02/07/2021).
- [12] Our World in Data. *Research and data to make progress against the world's largest problems*. URL: <https://ourworldindata.org> (acedido em 10/02/2021).

- [13] Master's in Data Science. *What Is Undersampling?* URL: <https://www.mastersindatascience.org/learning/statistics-data-science/undersampling/> (acedido em 02/10/2021).
- [14] Munmun De Choudhury et al. "Predicting depression via social media". Em: (2013).
- [15] Empex Digital. *50 social media statistics to inform your digital marketing in 2020*. URL: <http://www.empexdigital.com/blog/50-social-media-statistics-to-inform-your-digital-marketing-in-2020/> (acedido em 02/07/2021).
- [16] Center for Disease Control e Prevention. *2018 BRFSS Questionnaire*. URL: https://www.cdc.gov/brfss/questionnaires/pdf-ques/2018_BRFSS_English_Questionnaire-508.pdf (acedido em 20/07/2021).
- [17] Jr Dr. Augustus John Rush. *Inventory of Depressive Symptomatology - IDS and Quick Inventory of Depressive Symptomatology - QIDS*. URL: <http://ids-qids.org/validity.html> (acedido em 10/05/2021).
- [18] Catherine K Ettman et al. "Prevalence of depression symptoms in US adults before and during the COVID-19 pandemic". Em: *JAMA network open* 3.9 (2020), e2019686–e2019686.
- [19] Exame. *Estes gráficos mostram como a saúde mental virou prioridade na pandemia*. URL: <https://exame.com/carreira/estes-graficos-mostram-como-a-saude-mental-virou-prioridade-na-pandemia/> (acedido em 22/07/2021).
- [20] Forbes. *Reddit, Facebook, Twitter Worst For Mental Health Post-Coronavirus; YouTube Best*. URL: <https://www.forbes.com/sites/johnkoetsier/2020/04/26/reddit-worst-for-mental-health-for-covid-19-news-consumption-survey-says/?sh=1d2ff37131cf> (acedido em 12/03/2021).
- [21] Pablo Gamallo. *Depression Classification*. URL: https://github.com/gamallo/depression_classification/tree/master/lexicons (acedido em 22/09/2021).
- [22] Globo. *Sintomas de depressão aumentaram três vezes nos EUA durante a pandemia de Covid, diz estudo*. URL: <https://g1.globo.com/bemestar/coronavirus/noticia/2020/09/02/sintomas-de-depressao-aumentaram-tres-vezes-nos-eua-durante-a-pandemia-de-covid-diz-estudo.ghtml> (acedido em 03/07/2021).
- [23] Harvard. *The HANDS: The Harvard Department of Psychiatry National Depression Screening Day Scale*. URL: <http://www.schneckmed.org/MediaLibraries/SchneckMedical/documents/HANDS-Harvard-NDSD-Screening.pdf> (acedido em 22/07/2021).
- [24] Maryam Hasan, Elke Rundensteiner e Emmanuel Agu. "Emotex: Detecting emotions in twitter messages". Em: *2014 ASE BIGDATA/SOCIALCOM/CYBERSECURITY Conference, Stanford University, May 27-31, 2014*.
- [25] Institute for Health Metrics e Evaluation. *GBD Results Tools*. URL: <http://ghdx.healthdata.org/gbd-results-tool> (acedido em 22/07/2021).
- [26] Mingqing Hu e Bing Liu. *Bing sentiment lexicon*. URL: https://emilhvittfeldt.github.io/textdata/reference/lexicon_bing.html (acedido em 22/07/2021).

- [27] Global Web Index. *Social - Flagship Report 2019*. URL: <https://www.globalwebindex.com/hubfs/Downloads/2019%20Q1%20Social%20Flagship%20Report.pdf> (acedido em 22/07/2021).
- [28] Flavia Ismael et al. "Post-infection depressive, anxiety and post-traumatic stress symptoms: a retrospective cohort study with mild COVID-19 patients". Em: *medRxiv* (2020). DOI: 10.1101/2020.08.25.20182113. eprint: <https://www.medrxiv.org/content/early/2020/10/05/2020.08.25.20182113.full.pdf>. URL: <https://www.medrxiv.org/content/early/2020/10/05/2020.08.25.20182113>.
- [29] Matthew Jockers. *syuzhet: Extracts Sentiment and Sentiment-Derived Plot Arcs from Text*. URL: <https://cran.r-project.org/web/packages/syuzhet/index.html> (acedido em 22/07/2021).
- [30] Kff. *The Implications of COVID-19 for Mental Health and Substance Use*. URL: <https://www.kff.org/coronavirus-covid-19/issue-brief/the-implications-of-covid-19-for-mental-health-and-substance-use/> (acedido em 22/07/2021).
- [31] Kurt Kroenke, Robert L Spitzer e Janet BW Williams. "The PHQ-9: validity of a brief depression severity measure". Em: *Journal of general internal medicine* 16.9 (2001), pp. 606–613.
- [32] Akshi Kumar, Aditi Sharma e Anshika Arora. "Anxious Depression Prediction in Real-time Social Data". Em: *International Conference on Advances in Engineering Science Management & Technology (ICAESMT)-2019, Uttarakhand University, Dehradun, India*. 2019.
- [33] Scikit learn. *Count Vectorizer*. URL: https://scikit-learn.org/stable/modules/generated/sklearn.feature_extraction.text.CountVectorizer.html (acedido em 02/10/2021).
- [34] Scikit learn. *Linear SVC*. URL: <https://scikit-learn.org/stable/modules/generated/sklearn.svm.LinearSVC.html> (acedido em 02/10/2021).
- [35] Scikit learn. *Naive Bayes*. URL: https://scikit-learn.org/stable/modules/naive_bayes.html (acedido em 22/06/2021).
- [36] Scikit learn. *Support Vector Machines*. URL: <https://scikit-learn.org/stable/modules/svm.html> (acedido em 12/07/2021).
- [37] Scikit learn. *TF-IDF*. URL: https://scikit-learn.org/stable/modules/generated/sklearn.feature_extraction.text.TfidfVectorizer.html (acedido em 02/10/2021).
- [38] Angela Leis et al. "Detecting signs of depression in tweets in Spanish: behavioral and linguistic analysis". Em: *Journal of medical Internet research* 21.6 (2019), e14199.
- [39] Sean MacAvaney e Philip Resnik. *CLPsych 2021 Shared Task*. URL: <https://seanmacavaney.github.io/clpsych2021-shared-task/#practice-data> (acedido em 22/03/2021).

- [40] Mastercard. *Mastercard Survey Shows Consumers are Placing More Value on Family, Health, and Mental Well-Being than Before COVID*. URL: <https://www.mastercard.com/news/latin-america/en/newsroom/press-releases/pr-en/2020/october/mastercard-survey-reveals-essential-aspects-of-latin-americans-lives/> (acedido em 20/06/2021).
- [41] Karla McLaren. *Your Emotional Vocabulary List*. URL: <https://karlamclaren.com/wp-content/uploads/2020/01/Emotional-Vocabulary-and-Weasel-List.pdf> (acedido em 20/07/2021).
- [42] Albert Mehrabian. "Comparison of the PAD and PANAS as models for describing emotions and for differentiating anxiety from depression". Em: *Journal of psychopathology and behavioral assessment* 19.4 (1997), pp. 331–357.
- [43] Saif M. Mohammad. *NRC Emotion Lexicon*. URL: <http://saifmohammad.com/WebPages/NRC-Emotion-Lexicon.htm> (acedido em 02/08/2021).
- [44] Danielle Mowery et al. "Understanding depressive symptoms and psychosocial stressors on Twitter: a corpus-based study". Em: *Journal of medical Internet research* 19.2 (2017), e48.
- [45] Nature. *COVID's mental-health toll: how scientists are tracking a surge in depression*. URL: <https://www.nature.com/articles/d41586-021-00175-z> (acedido em 22/07/2021).
- [46] Yair Neuman et al. "Proactive screening for depression through metaphorical and automatic text analysis". Em: *Artificial intelligence in medicine* 56.1 (2012), pp. 19–25.
- [47] Finn Årup Nielsen. *AFINN Sentiment Lexicon*. URL: http://corpus-text.com/reference/sentiment_afinn.html (acedido em 24/07/2021).
- [48] NLTK. *Documentation*. URL: <https://www.nltk.org> (acedido em 02/10/2021).
- [49] Gwenn Schurgin O’Keeffe, Kathleen Clarke-Pearson et al. "The impact of social media on children, adolescents, and families". Em: *Pediatrics* 127.4 (2011), pp. 800–804.
- [50] Hussein Al-Olimat. *Social-media Depression Detector (SDD)*. URL: <https://github.com/halolimat/Social-media-Depression-Detector> (acedido em 22/09/2021).
- [51] World Health Organization. *Lexicon of psychiatric and mental health terms - Second Edition*. URL: <https://apps.who.int/iris/bitstream/handle/10665/39342/924154466X.pdf?sequence=1&isAllowed=y> (acedido em 12/07/2021).
- [52] Kuan-Yu Pan et al. "The mental health impact of the COVID-19 pandemic on people with and without depressive, anxiety, or obsessive-compulsive disorders: a longitudinal study of three Dutch case-control cohorts". Em: *The Lancet Psychiatry* 8.2 (2021), pp. 121–129.

- [53] Jonathan Posner, James A Russell e Bradley S Peterson. "The circumplex model of affect: An integrative approach to affective neuroscience, cognitive development, and psychopathology". Em: *Development and psychopathology* 17.3 (2005), pp. 715–734.
- [54] Royal Society for Public Health. *Status Of Mind*. URL: <https://www.rsph.org.uk/static/uploaded/d125b27c-0b62-41c5-a2c0155a8887cd01.pdf> (acedido em 22/09/2021).
- [55] Elizabeth Redden. *Pandemic Hurts Student Mental Health*. URL: <https://www.insidehighered.com/news/2020/07/13/survey-finds-higher-prevalence-depression-among-students-and-difficulties-accessing> (acedido em 20/07/2021).
- [56] A John Rush et al. "An evaluation of the quick inventory of depressive symptomatology and the hamilton rating scale for depression: a sequenced treatment alternatives to relieve depression trial report". Em: *Biological psychiatry* 59.6 (2006), pp. 493–501.
- [57] Sanarmed. *Distimia*. URL: <https://www.sanarmed.com/distimia-pospsq> (acedido em 17/07/2021).
- [58] Direção Geral da Saúde. *Depressão e Outras Perturbações Mentais Comuns*. URL: <https://www.dgs.pt/ficheiros-de-upload-2013/dms2017-depressao-e-outras-perturbacoes-mentais-comuns-pdf.aspx> (acedido em 22/07/2021).
- [59] Direção Geral da Saúde. *Porque se fala em saúde mental?* URL: <https://www.dgs.pt/paginas-de-sistema/saude-de-a-a-z/programa-nacional-para-a-saude-mental/perguntas-e-respostas.aspx> (acedido em 21/08/2021).
- [60] Direção Geral da Saúde. *Programa Nacional para a Saúde Mental - 2017*. URL: http://nocs.pt/wp-content/uploads/2017/11/DGS_PNSM_2017.10.09_v2.pdf (acedido em 22/07/2021).
- [61] Direção Geral da Saúde. *Saúde Mental em Tempos de Pandemia COVID-19*. URL: <https://sm-covid19.pt> (acedido em 23/07/2021).
- [62] Sociedade Portuguesa Psiquiatria e Saúde Mental. *Perturbação Mental em Números*. URL: <https://www.sppsm.org/informemente/guia-essencial-para-jornalistas/perturbacao-mental-em-numeros/> (acedido em 22/08/2021).
- [63] Scikit-learn. *Machine Learning in Python*. URL: <https://scikit-learn.org/stable/> (acedido em 02/10/2021).
- [64] Dr. Robert J. Spitzer, Dr. Janet B.W. Williams e Dr. Kurt Kroenke. *Patient Health Questionnaire -PHQ-9*. URL: <https://patient.info/doctor/patient-health-questionnaire-phq-9> (acedido em 22/07/2021).
- [65] Jini Jojo Stephen e P Prabu. "Detecting the magnitude of depression in Twitter users using sentiment analysis". Em: *International Journal of Electrical and Computer Engineering* 9.4 (2019), p. 3247.

- [66] Dhilip Subramanian. *Emoticon and Emoji in Text Mining*. URL: <https://pub.towardsai.net/emoticon-and-emoji-in-text-mining-7392c49f596a> (acedido em 22/06/2021).
- [67] Thesaurus. *Synonyms for depression*. URL: <https://www.thesaurus.com/browse/depression> (acedido em 23/07/2021).
- [68] Viktoriya Trifonova. *How the outbreak has changed the way we use social media*. URL: <https://blog.gwi.com/chart-of-the-week/social-media-amid-the-outbreak/> (acedido em 12/07/2021).
- [69] European Union. *Eurobarometer*. URL: <https://europa.eu/eurobarometer/screen/home> (acedido em 22/04/2021).
- [70] Vittude. *Quais são os impactos das redes sociais em nossa saúde mental?* URL: <https://www.vittude.com/blog/impactos-redes-sociais-saude-mental/> (acedido em 22/08/2021).
- [71] Who. *Depression and Other Common Mental Disorders - Global Health Estimates*. URL: <http://apps.who.int/iris/bitstream/handle/10665/254610/WHO-MSD-MER-2017.2-eng.pdf?sequence=1> (acedido em 02/05/2021).
- [72] Who. *Infographic - Major depression inadequate treatment (2017)*. URL: <https://www.euro.who.int/en/health-topics/noncommunicable-diseases/mental-health/data-and-resources/infographics-on-depression-world-health-day-2017/infographic-major-depression-inadequate-treatment-2017> (acedido em 12/08/2021).
- [73] Who. *Preventing depression in the WHO European Region*. URL: https://www.euro.who.int/__data/assets/pdf_file/0003/325947/New-Preventing-depression.pdf (acedido em 20/07/2021).
- [74] Wikipedia. *Cumulative distribution function*. URL: https://en.wikipedia.org/wiki/Cumulative_distribution_function (acedido em 02/10/2021).
- [75] Wikipedia. *Pearson correlation coefficient*. URL: https://en.wikipedia.org/wiki/Pearson_correlation_coefficient (acedido em 22/07/2021).
- [76] Wikipedia. *Zipf's law*. URL: https://en.wikipedia.org/wiki/Zipf_law (acedido em 02/10/2021).
- [77] Workana. *Healthy Home Offices: The Psychological Impact of Working from Home While Practicing Social Distancing*. URL: <https://blog.workana.com/en/freelancing/healthy-home-offices-psychological-impact-of-working-from-home-during-quarantine/> (acedido em 29/08/2021).
- [78] Meng Lin Xu, Paul De Boeck e Daniel Strunk. "An affective space view on depression and anxiety". Em: *International Journal of Methods in Psychiatric Research* 27.4 (2018). e1747 IJMPR-Feb-2018-0014.R1, e1747. DOI: <https://doi.org/10.1002/mpr.1747>. eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1002/mpr.1747>. URL: <https://onlinelibrary.wiley.com/doi/abs/10.1002/mpr.1747>.

- [79] Andrew Yates, Arman Cohan e Nazli Goharian. "Depression and self-harm risk assessment in online forums". Em: *arXiv preprint arXiv:1709.01848* (2017).
- [80] Amir Hossein Yazdavar et al. "Semi-supervised approach to monitoring clinical depressive symptoms in social media". Em: (2017), pp. 1191–1198.
- [81] Bu Zhong, Yakun Huang e Qian Liu. "Mental health toll from the coronavirus: Social media usage reveals Wuhan residents' depression and secondary trauma in the COVID-19 outbreak". Em: *Computers in human behavior* 114 (2021), p. 106524.