

Artur Pereira da Silva
Orientadora: Patrícia Vieira da Silva Barros

***HonorisClassifier: Classificador de Crimes
Contra a Honra***

Picos - PI
30 de maio de 2019

Artur Pereira da Silva
Orientadora: Patrícia Vieira da Silva Barros

***HonorisClassifiser*: Classificador de Crimes Contra a Honra**

Modelo de Trabalho de Conclusão de Curso em Bacharelado em Sistemas de Informação na Universidade Federal do Piauí. Este modelo está em conformidade com as normas ABNT.

Universidade Federal do Piauí
Campus Senador Helvídio Nunes de Barros
Bacharelado em Sistemas de Informação

Picos - PI
30 de maio de 2019

FICHA CATALOGRÁFICA
Serviço de Processamento Técnico da Universidade Federal do Piauí
Biblioteca José Albano de Macêdo

S586h Silva, Artur Pereira da.
HonorisClassifier: classificador de crimes contra a honra. /
Artur Pereira da Silva. -- Picos, PI, 2019.
37 f.
CD-ROM: 4 ¾ pol.

Trabalho de Conclusão de Curso (Bacharelado em Sistemas
de Informação) – Universidade Federal do Piauí, Picos, 2019.
Orientador(A): Prof^ª. Patrícia Vieira da Silva Barros.

1. Processamento de Linguagem Natural. 2. Classificação de
Texto (Computação). 3. Inteligência Artificial. I. Título.

CDD 005.1

Elaborada por Rafael Gomes de Sousa CRB 3/1163

TITULO

ARTUR PEREIRA DA SILVA

Monografia aprovada _____ como exigência parcial para obtenção do grau de Bacharel em Sistemas de Informação.

Data de Aprovação

Picos – PI, 12 de junho de 2019

Patricia Vieira da Silva Barros
Prof. Patrícia Vieira da Silva Barros

Francisca Pâmela Carvalho Nunes
Prof. Francisca Pâmela Carvalho Nunes

Francisco das Chagas Imperes Filho
Prof. Francisco das Chagas Imperes Filho

Agradecimentos

A Deus, por me dar discernimento, força e fé para realizar meus sonhos.

Agradeço a minha mãe, Valdileide Pereira, por confiar em mim e me dar a oportunidade de concretizar e encerrar mais esta caminhada. Sei que não mediu esforços para que este sonho se realizasse. Sem a compreensão, a ajuda e a sua confiança, nada disso seria possível hoje.

Agradeço também a minha orientadora Patrícia Vieira, que sempre esteve disponível para sanar as minhas dúvidas e que contribuiu durante a realização de todo o trabalho. Além deste trabalho, dedico o meu respeito e admiração.

Agradeço à Universidade Federal do Piauí por me proporcionar um ambiente criativo e amigável para os estudos. Sou grato à cada membro do corpo docente, à direção e a administração dessa instituição de ensino.

Se não puder voar, corra. Se não puder correr, ande. Se não puder andar, rasteje, mas continue em frente de qualquer jeito.

Martin Luther King

Resumo

Os crimes contra a honra são os crimes que atingem a integridade ou bem-estar moral de alguém, sendo subdivididos entre ameaça, calúnia, difamação e injúria. Os crimes contra a honra figuram-se entre os mais praticados na Internet. Independentemente de onde tal crime for praticado, será considerado um crime comum, visto que a Internet foi apenas o meio para essa propagação e qualquer delegacia está apta a cuidar do caso. Devido ao aumento do número de usuários utilizando redes sociais e aplicativos de mensagens, há uma falsa sensação de anonimato que parece estimular alguns usuários para a prática de crimes contra a honra e, juntamente com a falta de informação, muitas pessoas não apresentam queixa pois não sabem se a ofensa recebida configura crime. Este trabalho busca analisar sentenças de crimes contra a honra para categorização dos textos por tipo de crime, seguindo o Código Penal Brasileiro. O procedimento oferecido classifica os relatos coletados em cinco tipos de crimes (Ameaça, Calúnia, Difamação, Injúria e Injúria Racial). Foram utilizadas técnicas de Processamento de Linguagem Natural (PLN) para pré-processamento dos textos com auxílio da biblioteca NLTK, além da biblioteca TFLearn para o aprendizado profundo.

Palavras-chaves: Crimes contra a honra, Classificação de Texto, Inteligência Artificial, Processamento de Linguagem Natural.

Abstract

Crimes against honor are crimes that reach the Union, being subdivided between threats, slander, libel and slander. Crimes against honor are among the most practiced on the Internet. Independent-of-habit of crime by practiced, will be considered a common crime, since the Internet was only a means for this propagation and any police station is apt to take care of the case. To the increase of users use the networks socialise applications of messages, that is not possible to be used in the use of least used to be used in the crime, and with the lack of information, many people is not that that knows if an offense are crime. This article makes a joint search of crimes against honor by categorizing the texts by type of crime, following the Brazilian Penal Code. The process of classifying the crime rates of the five species (Threat, Calumny, Defamation, Injury and Racial Injury). Natural language processing (NLP) techniques were used for pre-processing with the aid of the NLTK library, as well as the TFLearn library for deep learning.

Keywords: Crimes Against an Honor, Text Classification, Artificial Intelligence, Natural Language Processing.

Lista de ilustrações

Figura 1 – Áreas relacionadas com a IA	19
Figura 2 – Ilustração de uma Rede Neural.	23
Figura 3 – Ilustração de uma Rede de Aprendizado Profundo.	23
Figura 4 – Arquitetura Geral do Sistema	28

Lista de tabelas

Tabela 1 – Componentes do Processamento de Linguagem Natural.	20
Tabela 2 – Tokenização de uma frase.	21
Tabela 3 – Remoção de Stopwords.	21
Tabela 4 – Stemização de uma frase.	22
Tabela 5 – Comparação entre os trabalhos relacionados	27
Tabela 6 – Quantidade de documentos por categoria	29
Tabela 7 – Parâmetros Usados no Pré-Processamento	31
Tabela 8 – Especificação de PP1	32
Tabela 9 – Especificação de PP2	32
Tabela 10 – Especificação de PP3	33
Tabela 11 – Especificação de PP4	33

Lista de abreviaturas e siglas

ACC	Acurácia
BOW	<i>Bag of Words</i>
CNN	<i>Convolutional Neural Network</i>
DNN	<i>Deep Neural Networks</i>
DL	<i>Deep Learning</i> (Aprendizagem Profunda)
HNET	<i>Highway Network</i>
NLTK	<i>Natural Language Toolkit</i>
MLP	<i>Multilayer Perceptron</i>
ML	Machine Learning
LSTM	<i>Long Short-Term Memory</i>
IA	Inteligência Artificial
ITER	Iterações
PLN	Processamento de Linguagem Natural
RNA	Redes Neurais Artificiais

Lista de símbolos

§ Parágrafo

Sumário

1	Introdução	14
1.1	Objetivos Gerais	15
1.2	Objetivos Específicos	15
1.3	Organização do Trabalho	15
2	Referencial Teórico	16
2.1	Honra	16
2.2	Crimes	16
2.2.1	Crimes Virtuais	16
2.2.2	Ameaça	17
2.2.3	Calúnia	17
2.2.4	Difamação	18
2.2.5	Injúria	18
2.2.5.1	Injúria Racial	18
2.3	Inteligência Artificial	19
2.4	Processamento de Linguagem Natural	20
2.4.1	Tokenização	21
2.4.2	Remoção de <i>Stopwords</i>	21
2.4.3	<i>Stemização</i>	22
2.5	Redes Neurais Artificiais	22
2.6	<i>Deep Learning</i>	23
2.6.1	<i>Deep Neural Networks</i>	24
2.6.1.1	<i>Multilayer perceptron</i>	24
2.6.2	<i>Convolutional Neural Network</i>	24
2.6.3	Redes Neurais Recorrentes	25
2.6.3.1	<i>Long short-term memory</i>	25
2.6.4	<i>Highway Network</i>	25
3	Trabalhos Relacionados	26
4	Desenvolvimento do Trabalho	28
4.1	Arquitetura Geral	28
4.2	Coleta de Documentos	29
4.3	Pré-Processamento dos Dados	29
4.3.1	Extração de características	30
4.4	Treinamento	30

4.5	Experimentos e Resultados	30
4.5.1	Testes com Variações de Parâmetros no Pré-Processamento	31
4.5.2	Métricas	31
4.5.2.1	Acurácia	31
4.5.2.2	Recall	31
4.5.2.3	F1-score	32
4.5.2.4	Precisão	32
4.5.3	Resultados Obtidos	32
5	Conclusão	34
	Referências	35

1 Introdução

Desde a antiguidade, uma das maiores preocupações dos cidadãos foi a proteção da sua honra. A legislação protetora que combate os crimes contra a honra evoluiu constantemente ao longo da história até chegar à atual divisão triplíce entre calúnia, difamação e injúria (TAMBOSI, 2016).

A honra é o patrimônio moral do indivíduo, considerado direito fundamental do ser humano, conforme estabelece o artigo 5o, inciso X, da Constituição Federal, sendo invioláveis a intimidade, a vida privada, a honra e a imagem das pessoas, assegurado o direito a indenização pelo dano material ou moral decorrente de sua violação.

Com o avanço dos meios de comunicações foram surgindo novos métodos de ofender a honra alheia, seja com a invenção da imprensa, seja com multiplicação dos aparelhos de rádios e televisão. Agora, há um novo estágio na difusão dos crimes contra a honra, que é a prática dos crimes contra honra na Internet.

A internet virou uma ferramenta indispensável para difusão da informação. Já é um dos meios de comunicação mais influentes na sociedade e sua influência não para de crescer. Além da internet proporcionar uma forma de divulgação de informações ou notícias, de maneira instantânea também permite a comunicação entre pessoas através das redes sociais. Com a comunicação rápida permitida pela internet, torna-se muito fácil espalhar boatos com uma velocidade sem precedentes, possibilitando que crimes contra a honra encontrem um local conveniente para a sua execução.

A falsa sensação de anonimato parece estimular milhares de internautas a publicarem conteúdo ofensivo de todo o tipo. As ofensas são dirigidas a pessoas específicas, figuras públicas, artistas, instituições privadas, grupos étnicos, religiosos. Independentemente de quem for o alvo, aqueles que se sentirem atingidos podem denunciar as manifestações e solicitar na Justiça a remoção das ofensas da rede (PRASS, 2014).

Publicações com conteúdos ofensivos em redes sociais e aplicativos, que vem se tornando cada vez mais frequentes, também estão sendo alvo do ingresso de ações judiciais, sejam indenizações de cunho moral ou patrimonial, sejam ações criminais, devido aos excessos indevidos da liberdade de expressão e à proteção que a lei assegura à honra do indivíduo (CORREA, 2015).

Diante desse contexto, se vê a necessidade de uma solução que facilite, tanto o leigo como os operadores do direito, diferenciar os tipos de crimes contra a honra e ajudar a vítima a tomar medidas cabíveis para que se puna o autor do crime. Neste trabalho foi desenvolvido uma arquitetura para um classificador com uso de aprendizagem profunda e processamento de linguagem natural, com o intuito de orientar possíveis vítimas de crimes contra a honra tipificando o crime sofrido a partir da análises de sentenças de crimes contra a honra.

1.1 Objetivos Gerais

Criar um classificador utilizando técnicas de processamento de linguagem natural e aprendizagem profunda para representar o conhecimento jurídico-criminal no contexto dos crimes contra a honra.

1.2 Objetivos Específicos

- Construção da arquitetura de um classificador que possibilite que o usuário visualize os resultados oferecidos pelo método de classificação.
- Experimentos comparativos para avaliação das melhores técnicas disponíveis para as fases de pré-processamento e classificação dos crimes.
- Determinar a melhor arquitetura de *Deep Learning* para classificar os crimes.

1.3 Organização do Trabalho

O presente trabalho está organizado em 5 capítulos. Após esta Introdução, mais quatro capítulos tratam da revisão bibliográfica e detalhando o sistema proposto, assim como dos experimentos realizados.

- O capítulo 2 aborda as definições e termos técnicos que serão utilizados durante este projeto, com a finalidade de trazer uma melhor compreensão para o leitor.
- No capítulo 3 será mostrado os trabalhos mais relevantes e relacionados ao projeto.
- No capítulo 4 são abordadas as etapas de desenvolvimento do trabalho, iniciando pela coleta de documentos para base de dados, pré-processamento dos dados, seguido pelo treinamento na rede neural e finalizando com os experimentos e resultados.
- O capítulo 5 é apresentado as conclusões e trabalhos futuros.

2 Referencial Teórico

Esta seção aborda as definições e termos técnicos que serão utilizados durante este pré-projeto, com a finalidade de trazer uma melhor compreensão para o leitor.

2.1 Honra

Honra, proveniente do latim *honor*, indica a própria dignidade de uma pessoa, que vive com honestidade e probidade, pautando seu modo de vida nos ditames da moral. Para o jurista italiano Adriano de Cupis a honra é a dignidade pessoal refletida na consideração dos outros (honra objetiva) e no sentimento da própria pessoa (honra subjetiva). Entretanto, ainda que a conduta de determinado cidadão não esteja conforme a conduta que a sociedade ou a respectiva comunidade tenha adotado como parâmetro de honorabilidade ou probidade, ainda que se comporte de forma a não coadunar seus atos com sua dignidade, não há que desconsiderá-la (MARQUES, 2010).

Lorenci (2002), acrescenta que à honra subjetiva, pode ser analisada na forma do sentimento e no juízo que cada um faz de si mesmo, e é dividida em honra-dignidade que diz respeito às qualidades morais da pessoa e honra-decoro que preza pelas qualidades intelectuais e físicas.

Segundo Lorenci (2002) a honra objetiva diz respeito ao conceito que os outros fazem de alguém, portanto quem ataca a honra objetiva de outra pessoa, também estará criando uma situação em que poderá acarretar em uma mudança de conceito da sociedade em relação a pessoa ofendida, visto que lhe imputando o fato seja ele falso ou ofensivo a sua reputação, estará conseqüentemente dificultando seu convívio social.

2.2 Crimes

Conforme estabelece o artigo 1º da Lei de introdução do Código Penal (decreto-lei n. 2.848, de 7-12-940) e da Lei das Contravenções Penais (decreto-lei n. 3.688, de 3 outubro de 1941), considera-se crime a infração penal que a lei comina pena de reclusão ou de detenção, quer isoladamente, quer alternativa ou cumulativamente com a pena de multa; contravenção, a infração penal a que a lei comina, isoladamente, pena de prisão simples ou de multa, ou ambas, alternativa ou cumulativamente.

2.2.1 Crimes Virtuais

Crimes virtuais são delitos praticados através da internet que podem ser enquadrados no Código Penal Brasileiro resultando em punições como pagamento de indenização ou

prisão.

Os crimes digitais são cada vez mais comuns porque as pessoas cultivam a sensação de que o ambiente virtual é uma terra sem leis. A falta de denúncias também incentiva fortemente seu crescimento.

De acordo com o delegado Guilherme Iusten, da Seção de Combate a Roubos a Bancos (Serb):

“Os tipos mais comuns de crimes na internet são os de calúnia e difamação, que já estão previstos na lei desde 1940. Entretanto, não tratamos como crimes virtuais, pois a internet foi apenas um meio para essa propagação, ele vai ser tratado como um crime comum e qualquer delegacia está apta a cuidar do caso”.¹

Muito se fala sobre a carência de um conjunto de normas e sanções jurídicas dedicadas somente para os crimes digitais. Porém, existindo ou não uma legislação específica para este assunto, quando a internet é usada como uma ferramenta para a prática de delitos e violência, estes crimes serão adaptados ao código penal já existente e os agressores e golpistas serão punidos da mesma forma.

2.2.2 Ameaça

Intimidar alguém impondo-lhe temor de sofrer mal injusto e grave é crime de ameaça. Exemplo: jurar alguém de morte.

Para a ocorrência do crime não precisa que o criminoso cumpra o que disse, basta que ele tenha intenção de causar medo e que a vítima se sinta atemorizada. Conforme estabelece o Código Penal Brasileiro:

Art. 147 - Ameaçar alguém, por palavra, escrito ou gesto, ou qualquer outro meio simbólico, de causar-lhe mal injusto e grave:

Pena - detenção, de um a seis meses, ou multa.

Parágrafo único - Somente se procede mediante representação

2.2.3 Calúnia

Comete calúnia quem faz uma falsa acusação, alegando que determinada pessoa cometeu um crime, como por exemplo, acusar alguém de assassinato sem que a pessoa de fato o tenha efetuado. Conforme estabelece o Código Penal Brasileiro:

Art. 138 - Caluniar alguém, imputando-lhe falsamente fato definido como crime:

Pena - detenção, de seis meses a dois anos, e multa.

§ 1º - Na mesma pena incorre quem, sabendo falsa a imputação, a propala ou divulga.

§ 2º - É punível a calúnia contra os mortos.

¹ <https://glo.bo/2jkWzE8>

A calúnia atinge a honra objetiva e se consuma quando um terceiro toma conhecimento da iludida imputação. Este crime se aproxima da difamação, pois ambos atingem a honra objetiva de alguém, por meio da imputação de um fato e por se consumarem quando terceiros tomarem conhecimento de tal imputação (RANGEL, 2015).

2.2.4 Difamação

A difamação consiste em denegrir a reputação de uma pessoa relatando algum fato, verdadeiro ou falso, referente a ela. No caso, como exemplo, seria afirmar que um funcionário estaria trabalhando sob o efeito de álcool. Embora trabalhar alcoolizado não seja considerado crime, a acusação seria negativa para a imagem da pessoa, prejudicando sua reputação. (PEREIRA, 2016). Conforme estabelece o Código Penal Brasileiro:

Art. 139 - Difamar alguém, imputando-lhe fato ofensivo à sua reputação:

Pena - detenção, de três meses a um ano, e multa.

Exceção da verdade

Parágrafo único - A exceção da verdade somente se admite se o ofendido é funcionário público e a ofensa é relativa ao exercício de suas funções.

2.2.5 Injúria

Consiste no xingamento ofensivo a alguém. Por sua vez, a injúria atinge a sua dignidade (honra subjetiva) e se consuma quando a vítima toma conhecimento do xingamento ofensivo, ou seja, atribuir uma qualidade negativa a alguém, ainda que verdadeira. Por exemplo: Chamar uma pessoa de burra e incapaz nas atividades profissionais. Conforme estabelece o Código Penal Brasileiro:

Art. 140 - Injuriar alguém, ofendendo-lhe a dignidade ou o decoro:

Pena - detenção, de um a seis meses, ou multa.

§ 1º - O juiz pode deixar de aplicar a pena:

I - quando o ofendido, de forma reprovável, provocou diretamente a injúria;

II - no caso de retorsão imediata, que consista em outra injúria.

§ 2º - Se a injúria consiste em violência ou vias de fato, que, por sua natureza ou pelo meio empregado, se considerem aviltantes:

Pena - detenção, de três meses a um ano, e multa, além da pena correspondente à violência.

2.2.5.1 Injúria Racial

A injúria racial é considerada um crime contra a honra, e consiste na ofensa à dignidade ou decoro de alguém, utilizando-se elementos referentes a raça, cor, etnia, religião, origem ou a condição de pessoa idosa ou portadora de deficiência. Conforme estabelece o Código Penal Brasileiro:

§ 3o Se a injúria consiste na utilização de elementos referentes a raça, cor, etnia, religião, origem ou a condição de pessoa idosa ou portadora de deficiência: (Redação dada pela Lei nº 10.741, de 2003)

Pena - reclusão de um a três anos e multa. (Incluído pela Lei nº 9.459, de 1997)

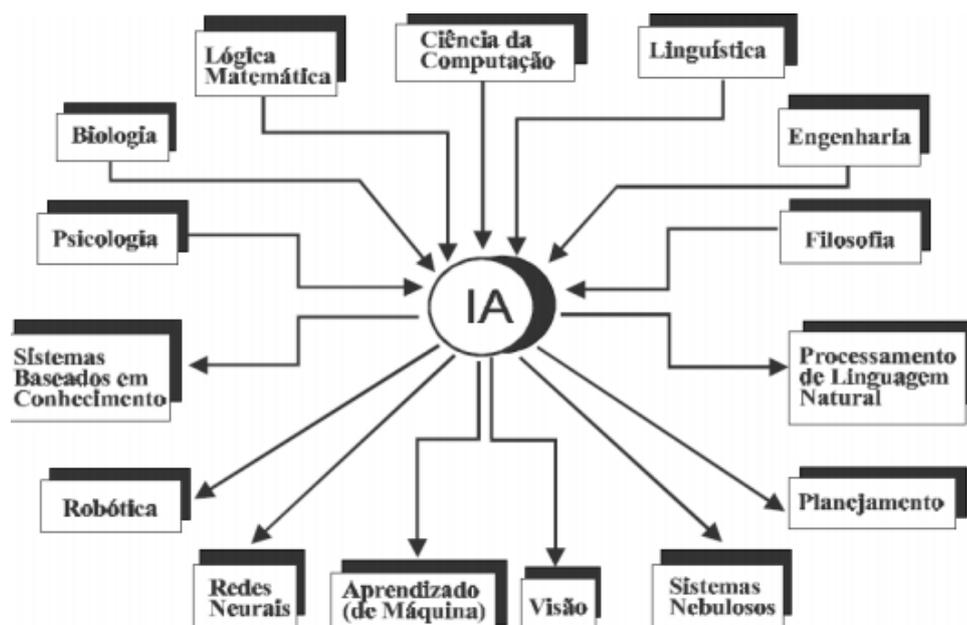
2.3 Inteligência Artificial

Inteligência Artificial (IA) é um ramo da ciência da computação que se propõe a elaborar dispositivos que simulem a capacidade humana de raciocinar, perceber, tomar decisões e resolver problemas, enfim, a capacidade de ser inteligente (PEREIRA; GOMES; FÁVERO, 2011).

A inteligência artificial faz parte dos estudos de ciências da computação. Os programas utilizam a mesma linguagem de sistemas convencionais, mas com uma lógica diferente. Existem várias maneiras de se fazer essa programação. Em alguns casos, o sistema inteligente funciona com uma lógica simples - se a pergunta for x, a resposta é y. Em outros casos, como os estudos em redes neurais, a máquina tenta reproduzir o funcionamento dos neurônios humanos, em que as informações vão sendo transmitidas de uma célula a outra e se combinando com outros dados para se chegar a uma solução (OLIVEIRA et al., 2013).

A aplicação da IA pode ser feita em diversas áreas como por exemplo no esquema a seguir:

Figura 1 – Áreas relacionadas com a IA



Fonte: (CURY et al., 2018)

A IA também é utilizada no processamento de uma linguagem natural dos humanos por meio da análise da voz. Em geral, existem três tipos de processamento de linguagem natural: o comando, que reconhece dezenas de palavras; o discreto, que reconhece a fala direta, desde que com pausas entre palavras; e o contínuo que consegue reconhecer a fala natural (NETO et al., 2018).

O processamento de uma linguagem natural permitiu o desenvolvimento de diversos tipos de softwares, dentre eles o Google Tradutor. Além disso, o processamento de linguagem natural consegue associar palavras digitalizadas, com palavras faladas, tudo isso por meio de sensores, dentre eles, os microfones (NETO et al., 2018).

2.4 Processamento de Linguagem Natural

O Processamento de Linguagem Natural (PLN) é um campo de extrema complexidade, em que devemos considerar diversos tipos de conhecimentos e agrupar competências variadas e complementares. O objetivo maior da PLN é tratar a língua de maneira automática através de formalismos que explicitem os conhecimentos linguísticos, tornando-os passíveis de serem tratados por computador (BRITO, 2000).

A PLN certamente não é uma disciplina recente. O primeiro motor de busca que permitiu pesquisar um banco de dados em linguagem natural, SMART, surgiu no início da década de 1960, assim como os primeiros sistemas para conversar com humanos. O exemplo mais conhecido é ELIZA, um sistema que simulou um "rogeriano psicoterapeuta".

Segundo Muller (2006), o Processamento de Linguagem Natural pode ser dividido em quatro componentes, como visto na Tabela 1.

Tabela 1 – Componentes do Processamento de Linguagem Natural.

Componente	Descrição
Análise Morfológica	Permite reconhecer as palavras sob as diferentes formas (conjugação, declinação, etc.) que sua função na sentença lhes dá.
Análise Sintática	Trabalha com as relações formais entre palavras, e é uma das partes mais importantes das análises.
Análise Semântica	Visa representar o significado de cada palavra, ou o significado de um conjunto de palavras (sentença), baseados nas suas construções sintáticas.
Análise Pragmática	Diz respeito ao contexto em que as sentenças se aplicam, baseando-se nos sentidos extraídos anteriormente na análise semântica.

Fonte: Textos adaptados de Muller (2006)

Conforme descreve Silva (2017) de modo geral, no PLN buscam-se soluções para questões computacionais que requerem o tratamento computacional de uma ou mais línguas naturais, quer sejam escritas ou faladas. Mais precisamente, o PLN dedica-se a propor e desenvolver sistemas computacionais que têm a língua natural escrita como objeto pri-

mário. Para tanto, linguistas e cientistas da computação, buscam fundamentos em várias disciplinas. Como Filosofia da Linguagem, Psicologia, Lógica, Inteligência Artificial, Matemática, Ciência da Computação, Linguística Computacional e Linguística.

A seguir, são comentadas 3 tarefas muito utilizadas no pré-processamento textual: Tokenização, Remoção de *Stopwords* e *Stemização*.

2.4.1 Tokenização

O primeiro passo de uma operação de pré-processamento é a tokenização ou atomização. Sua execução tem como finalidade seccionar um documento textual em unidades mínimas, mas que expressem a mesma semântica original do texto. O termo token é utilizado para designar estas unidades, que geralmente correspondem a somente uma palavra do texto, porém há casos em que estas unidades textuais não podem ser consideradas palavras ou apresentam mais de uma palavra (SOARES, 2008). Na Tabela 2 é dado um exemplo de Tokenização.

Tabela 2 – Tokenização de uma frase.

Entrada
Os crimes contra a honra estão subdivididos entre calúnia, injúria e difamação
Saída
['os', 'crimes', 'a', 'honra', 'contra', 'estão', 'subdivididos', 'entre', 'calúnia', ',', 'injúria', 'e', 'difamação']

Fonte: Elaborado pelo Autor

2.4.2 Remoção de *Stopwords*

Uma das tarefas muito utilizadas no pré-processamento de textos é a remoção de *stopwords*. Esse método consiste em remover palavras muito frequentes, pois na maioria das vezes não são informações relevantes para a construção do modelo. Remover *stopwords* somente quando não forem relevantes para a tarefa. No caso da Análise de Sentimentos, não poderíamos remover a *stopword* “não”, pois traz uma conotação de negatividade para a sentença, indicando justamente o sentimento transmitido (SILVA, 2017). A Tabela 3 mostra um exemplo de remoção de *Stopwords*

Tabela 3 – Remoção de *Stopwords*.

Entrada
Os crimes contra a honra estão subdivididos entre calúnia, injúria e difamação
Saída
['crimes', 'contra', 'honra', 'subdivididos', 'calúnia', ',', 'injúria', 'difamação']

Fonte: Elaborado pelo Autor

2.4.3 Stemização

Segundo [Fernandes \(2016\)](#) a *stemização* é o processo de reduzir palavras flexionadas à sua raiz, porém essa redução não precisa, necessariamente, chegar à raiz morfológica da palavra. A raiz obtida geralmente é o suficiente para mapear palavras relacionadas à uma raiz comum, mesmo se esta não for uma raiz válida.

A consequência da aplicação de algoritmos de *stemming* consiste na remoção de prefixos ou sufixos de um termo e até mesmo na transformação de verbos para suas formas no infinitivo. Por exemplo, as palavras ouvir, ouvi, ouviriam, ouve e ouvindo seriam reduzidas para um mesmo *stem*: ouv. Por isso esse método diminui a dimensionalidade dos vetores dentro de um BOW, ao invés de analisar a frequência dos termos, a análise é feita sob a quantidade de vezes que um *stem* aparece em um documento ([FERNANDES, 2016](#)). A Tabela 4 abaixo mostra um exemplo de *Stemização* de uma frase.

Tabela 4 – Stemização de uma frase.

Entrada
Os crimes contra a honra estão subdivididos entre calúnia, injúria e difamação
Saída
['crim', 'contr', 'honr', 'subdiv', 'calún', ',', 'injúr', 'difam']

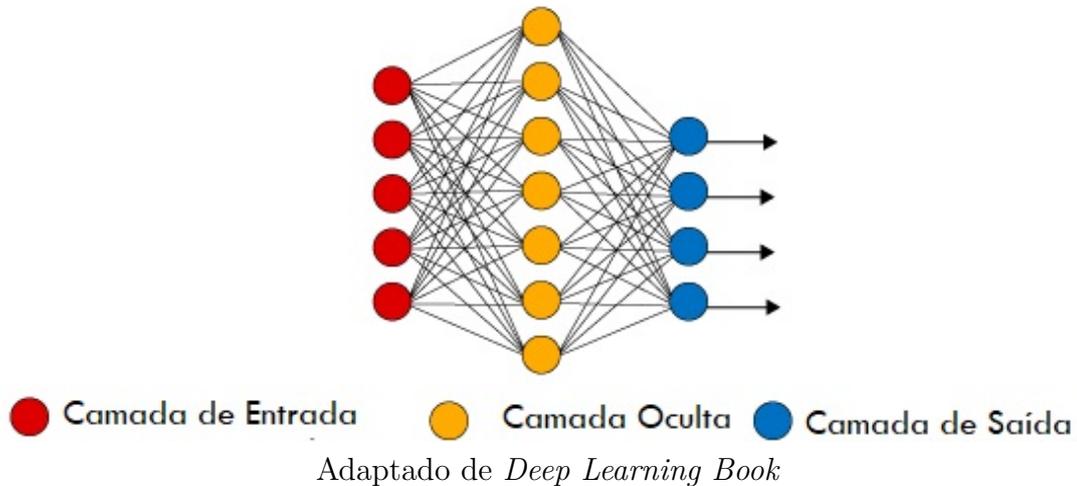
Fonte: Elaborado pelo Autor

2.5 Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA), ou simplesmente Redes Neurais (RN), ou ainda métodos conexionistas, compreendem uma metodologia para solucionar problemas de IA, a partir de um sistema que possui circuitos simuladores do cérebro humano, inclusive de seu comportamento, ou seja, aprendendo, errando e fazendo descobertas. São técnicas computacionais, que apresentam modelo inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento por meio da experiência ([GUIMARÃES et al., 2008](#)).

Uma RNA é composta de 3 partes: Camada de entrada, onde o dado entra (exemplos: pixel, letra, som); Camadas intermediárias ou ocultas, onde os dados passam por funções diversas (como funções de ativação); Camada de saída, onde o resultado é disposto da forma desejada (um valor, uma categoria, 2 valores etc) ([CUTTLE et al., 2018](#)). A Figura 2 demonstra uma Rede Neural.

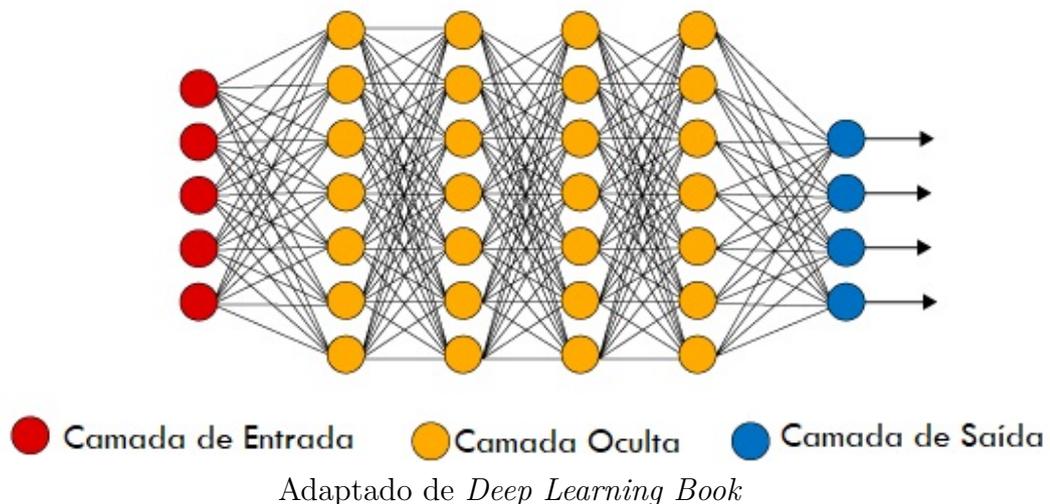
Figura 2 – Ilustração de uma Rede Neural.



2.6 *Deep Learning*

Deep Learning (DL) ou aprendizagem profunda difere-se das redes neurais convencionais no sentido de que elas possuem mais nós, meios mais complexos de interconexões de camadas, demandam maior poder computacional para seu treinamento e têm extração automática dos parâmetros (PATRÍCIO et al., 2019). A Figura 3 demonstra uma Rede de Aprendizado Profundo.

Figura 3 – Ilustração de uma Rede de Aprendizado Profundo.



DL usa camadas de neurônios matemáticos para processar dados, compreender a fala humana e reconhecer objetos visualmente. A informação é passada através de cada camada, com a saída da camada anterior fornecendo entrada para a próxima camada. A primeira camada em uma rede é chamada de camada de entrada, enquanto a última é

chamada de camada de saída. Todas as camadas entre as duas são referidas como camadas ocultas. Cada camada é tipicamente um algoritmo simples e uniforme contendo um tipo de função de ativação.

A DL é responsável por avanços recentes em visão computacional, reconhecimento de fala, processamento de linguagem natural e reconhecimento de áudio. O aprendizado profundo é baseado no conceito de redes neurais artificiais, ou sistemas computacionais que imitam a maneira como o cérebro humano funciona².

2.6.1 *Deep Neural Networks*

As redes neurais de múltiplas camadas, do inglês *Deep Neural Networks* (DNN) são modelos de aprendizado que possuem muitos parâmetros ajustáveis e consomem muitos recursos durante a etapa de treino. No entanto, o surgimento recente de placas gráficas a baixo custo e avanços teóricos que diminuem o número de cálculos por parâmetro, tornou viável o treinamento desse tipo de algoritmo em tarefas que envolvem muitos dados (ROCHA, 2015). As DNNs alcançaram grande sucesso prático em muitas tarefas de aprendizado de máquina, como o reconhecimento de fala, classificação de imagem e processamento linguagem natural.

2.6.1.1 *Multilayer perceptron*

O *Multilayer Perceptron* (MLP) consiste em uma rede neural perceptron, formada por um conjunto de camadas. Este classificador tem em sua arquitetura uma camada de entrada, uma ou mais camadas ocultas, e uma camada de saída. A camada de entrada consiste em várias unidades que recebem entradas do mundo real, enquanto a camada de saída retorna os resultados para o mundo real, já as camadas ocultas são responsáveis por extrair padrões subjacentes das entradas (MONIKA; VENKATESAN, 2015).

2.6.2 *Convolutional Neural Network*

Convolutional Neural Network (CNN) é uma arquitetura de *Deep Learning*, sendo uma variação da rede neural artificial perceptron de múltiplas camadas. Tradicionalmente, pensamos que uma CNN é uma rede neural especializada no processamento de uma grade de valores, como uma imagem. Como as CNNs, podem produzir apenas vetores de tamanho fixo, o ajuste natural para eles parece estar nas tarefas de classificação, como Análise de Sentimento, Detecção de Spam ou Categorização por Tópico³.

² <http://bit.ly/2W0C7NW>

³ <http://bit.ly/2I4ho2I>

2.6.3 Redes Neurais Recorrentes

De acordo com [Carvalho et al. \(2018\)](#) redes neurais recorrentes são técnicas de aprendizado de máquina que apresentam neurônios recorrentes. Como estas incluem loops, elas podem armazenar informações ao processar novas entradas. Portanto, a memória as torna ideais para tarefas de processamento de dados que utilizam séries temporais.

2.6.3.1 *Long short-term memory*

A *Long Short-Term Memory* (LSTM) é uma arquitetura de rede neural artificial recorrente usada no campo da aprendizagem profunda. Ao contrário das redes neurais padrão, o LSTM possui conexões de realimentação que o tornam um “computador de uso geral”. Ele pode não apenas processar pontos de dados únicos, mas também sequências inteiras de dados. As LSTM são as ferramentas diretas para pesquisadores de PNL e fornecem resultados de última geração em muitas tarefas diferentes de PNL, incluindo modelagem de linguagem, tradução de máquina neural, análise de sentimentos e assim por diante.

2.6.4 *Highway Network*

Highway Network (HNET) ou Redes Rodoviárias é uma abordagem para otimizar redes e aumentar sua profundidade. As redes rodoviárias utilizam mecanismos de *gating* aprendidos para regular o fluxo de informação, inspirados nas redes neurais recorrentes de Long Short-Term Memory (LSTM) ([YAO et al., 2019](#)).

3 Trabalhos Relacionados

No que refere-se aos trabalhos desta linha de pesquisa, pode-se observar uma tendência de crescimento no uso de técnicas de Aprendizado Profundo, para classificação de texto. A seguir são descritos os trabalhos relacionados com objetivos semelhantes a este.

[Pineda et al. \(2019\)](#) fazem o uso de redes neurais recorrentes de longo prazo (LSTM-RNN) para facilitar a classificação de narrativas em clínicas humanas e veterinárias. Essa abordagem de aprendizagem profunda (modelo LSTM) foi capaz de classificar automaticamente narrativas médicas sem o uso de qualquer conhecimento de domínio ou curadoria manual de recursos.

[He, Guan e Dai \(2019\)](#) utiliza um novo modelo baseado em CNN para classificar relações entre conceitos médicos em registros clínicos. Uma operação multi-pool ajudou a extrair características mais precisas e mais ricas na camada convolucional, indicando que a extração de características baseada no posicionamento de pares de conceitos pode melhorar a eficácia da classificação de relações em registros clínicos.

[Undavia Samir \(2018\)](#) faz o uso de Aprendizado Profundo em um sistema que aplica esses métodos ao problema de classificação de documentos de opiniões de tribunais judiciais. Também é apresentado uma CNN usada com vetores de palavras pré-treinados que mostra melhorias sobre o estado da arte aplicado ao conjunto de dados. O melhor sistema (word2vec + CNN) alcança 72,4% de precisão ao classificar as decisões judiciais em 15 categorias amplas e 31,9% de precisão ao classificar entre 279 categorias mais refinadas.

[Banerjee et al. \(2018\)](#) propõe métodos de aprendizagem profunda de ponta para extração de informações de relatórios de texto livre de imagens médicas em uma escala multi-institucional. Foram propostos dois modelos distintos de aprendizagem profunda - (i) CNN Word - Glove, e (ii) Rede Neural Recorrente Hierárquica Baseada na Atenção de Domínio (DPA-HNN), para sintetizar informações sobre êmbolos pulmonares de relatórios de radiologia de tomografia computadorizada torácica coletados de quatro grandes centros de saúde.

[Han et al. \(2018\)](#) propõe um modelo de predição de intervalo de sentenciamento de casos criminais baseado em uma CNN, e através do método de convolução multi-core, aumenta muito a capacidade de generalização e desempenho de previsão do modelo. Através deste intervalo de sentença, o advogado entende que a punição do tribunal para tais casos é geralmente dada, o que será um importante fator de referência

[Xing, Xu e Wang \(2018\)](#) aplica um método para obter a representação semântica de artigos jurídicos usando KG (Keywords Group) e redes neurais de convolução (CNNs). KG (Keywords Group) é uma coleção de palavras que contém algumas palavras-chave em evidência, como assassinato, roubo, são bastante valiosas para os juízes classificarem as evidências. Primeiro, foi marcado manualmente um conjunto de 50 palavras no grupo

de palavras-chave iniciais em um conjunto de dados, sendo cada uma delas uma palavra frequente e importantes.

Gambäck e Sikdar (2017) aplica um sistema para classificação de texto de discurso de ódio do Twitter baseado em um modelo de CNN. O classificador atribui cada tweet a um dos quatro categorias pré-definidas: racismo, sexismo, ambos (racismo e sexismo) e nenhum dos dois modelos CNN foram criados com base em diferentes conjuntos de vetores de entrada que foram alimentados nas redes neurais para treinamento e classificação.

Sboev et al. (2016) Foi feita uma análise comparativa de diferentes algoritmos de aprendizagem de máquina para classificação textual de acordo com o gênero dos autores, mostrou que entre os algoritmos estudados e amplamente utilizados os modelos de redes neurais (CNN + LSTM) demonstram maior nível de precisão, mesmo a base sendo muito limitada de conjuntos e recursos gramaticais. A tabela 5, apresenta as principais características dos trabalhos relacionados a esta preposição.

Tabela 5 – Comparação entre os trabalhos relacionados

Autor	Nº amostras	Tecnologias Utilizadas	Área	Acurácia	Categorias
Pineda et al. (2019)	3.124	LSTM-RNN	Saúde	91.53%	17
He, Guan e Dai (2019)	426	CNN	Saúde	72.90%	3
Undavia Samir (2018)	842	CNN	Jurídico	72.40%	15
Banerjee et al. (2018)	4.512	DPA-HNN	Saúde	99.99%	2
Han et al. (2018)	2.000	CNN	Jurídico	91.30%	4
Xing, Xu e Wang (2018)	10.000	CNN	Jurídico	70.56%	3
Gambäck e Sikdar (2017)	6.655	CNN	Jurídico	86.68%	4
Sboev et al. (2016)	1.867	CNN+LSTM	Semântica	86.01%	3
HonorisClassifier (2019)	332	DNN	Jurídico	98.40%	5

Os trabalhos aqui apresentados não se aprofundaram na etapa de pré-processamento do texto, tendo como foco principal a etapa de extração do conhecimento para realização das tarefas pretendidas. As técnicas usadas no pré-processamento dos dados podem influenciar de forma significativa no desempenho da classificação, como pode ser visto nos experimentos realizados nesse trabalho (Capítulo 4).

Esse trabalho pode ser associado a área Jurídica, por estudar crimes contra a honra. Não foram encontrados trabalhos relacionados a categorização de relatos pessoais, de pacientes com transtornos mentais, nas pesquisas realizadas no Google Acadêmico ¹

O capítulo a seguir apresentará o processo de desenvolvimento do classificador proposto neste trabalho, o *HonorisClassifier*, que faz uso de PLN para categorização de crimes contra a honra.

¹ <https://scholar.google.com.br/>

4 Desenvolvimento do Trabalho

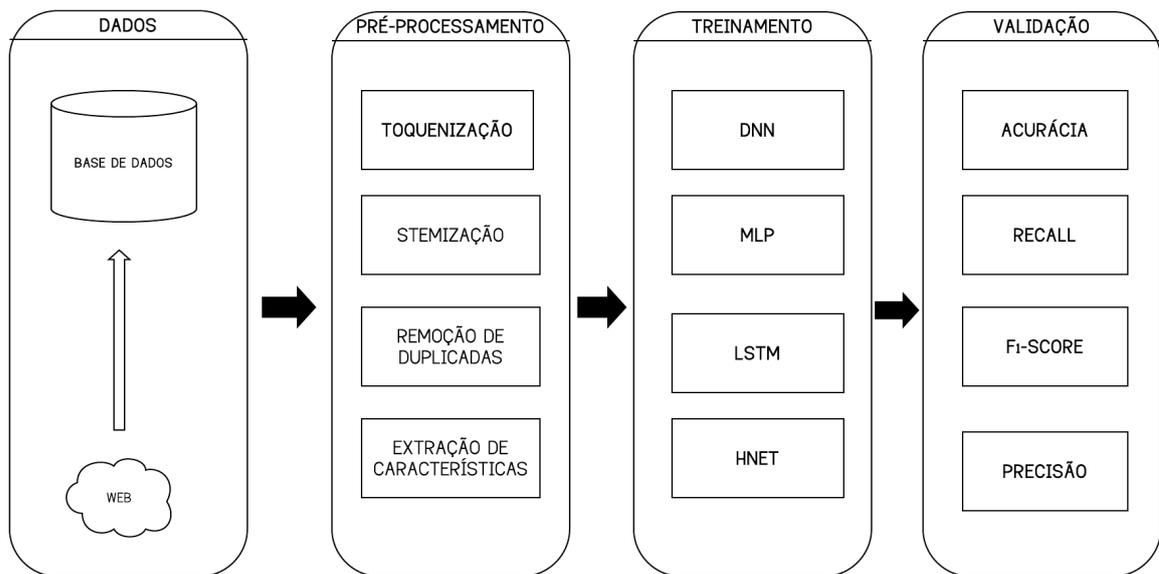
No decorrer deste capítulo são abordados ambiente e metodologia utilizada durante o desenvolvimento do presente trabalho.

4.1 Arquitetura Geral

A Figura 4 exibe a arquitetura geral do sistema. Ela é composta pelos seguintes módulos: Base de dados, pré-processamento dos dados transcritos, treinamento e validação.

A aquisição dos documentos textuais foi realizada de forma manual. Essa fase envolveu a seleção das bases de texto, ou seja, dos relatos que constituíram os dados de interesse. Nessa etapa, foram realizadas breves leituras de diversas sentenças para selecionar aquelas narradas entre crimes contra a honra.

Figura 4 – Arquitetura Geral do Sistema



Fonte: Elaborado pelo Autor

No pré-processamento dos dados textuais, houve a preparação dos dados de texto para as fases posteriores de execução das tarefas de processamento. Nessa etapa, os textos foram padronizados e estruturados. A seguir, realizou-se a redução dimensional dos dados.

O módulo de treinamento recebe os documentos pré-processados, já preparados para extração do conhecimento. Nessa fase, um conjunto de documentos etiquetados é usado no treinamento do algoritmo de aprendizagem de máquina, para possibilitar a categorização de novos documentos.

Após a finalização da etapa de treinamento, é necessário validar os resultados e discutir prováveis melhorias. Essa metodologia utiliza métricas comumente aplicadas a sistemas baseados em processamento de linguagem natural.

4.2 Coleta de Documentos

Os documentos usados como base para classificação dos crimes contra a honra foram coletados de diversas fontes, tais como: Código Penal Brasileiro, blogs, sites voltados para discussões jurídicas, livros, entre outros. As distribuições de classes do conjunto de dados são mostradas na Tabela 6.

Tabela 6 – Quantidade de documentos por categoria

Crimes	Número de amostras
Ameaça	10
Calúnia	125
Difamação	53
Injúria	79
Injúria Racial	61

Fonte: Elaborado pelo Autor

A escolha dos arquivos de texto teve como critério narrativas de sentenças publicadas de crimes contra a honra. Todas as narrativas utilizadas são de casos que aconteceram no Brasil. Foram utilizadas 5 categorias (Ameaça, Calúnia, Difamação, Injúria e Injúria Racial). O tamanho total do conjunto de dados é de 331 amostras.

4.3 Pré-Processamento dos Dados

Dados textuais, geralmente, não são encontrados em formato adequado para extração de conhecimento, sendo necessário muitas vezes o uso de métodos de extração e integração, transformação, limpeza, seleção e redução de volume desses dados (NUNES, 2016).

Algumas técnicas podem ser aplicadas na fase de pré-processamento dos dados: Tokenização, Remoção de *Stopwords*, *Stemming*, Conversão de Letras para Minúsculas e Análise da Frequência de Palavras utilizando vetores ponderados segundo a fórmula $TF*IDF^1$ (NUNES, 2016).

Após coletar os dados que foram utilizados no sistema para o processo de treinamento do classificador, primeiro foi criada uma base com dados para executar este treinamento, estes dados foram classificados manualmente de forma que serviram como parâmetro para realizar um treinamento confiável.

¹ <http://www.tfidf.com/>

Para pré-processar os dados, foram utilizadas 3 técnicas de pré-processamento. O primeiro passo no pré-processamento foi a tokenização de cada palavra na base de dados. A próxima técnica usada foi a *stemização* das palavras e a última técnica utilizada foi a remoção das palavras duplicadas. Durante todo processo de pré-processamento foi utilizada a biblioteca *Natural Language Toolkit* (NLTK).

A NLTK é um módulo utilizado no auxílio de construção de programas em Python para manipulação de dados de linguagem natural(humana). Este módulo fornece inúmeras interfaces para uso com mais de 50 corpora e recursos léxicos, além de conter um grande conjunto de bibliotecas voltadas para uso em mineração de textos para tokenização, stemming lematização, classificação, análise e raciocínio semântico (NLTK, 2018).

4.3.1 Extração de características

O mapeamento de dados textuais para vetores com valor real é chamado de extração de características. A técnica usada neste trabalho para representar numericamente textos é chamado de *Bag of Words* (BOW). O BOW é um método para extrair recursos de documentos de texto. Esses recursos podem ser usados para treinar algoritmos de aprendizado de máquina. Ele cria um vocabulário de todas as palavras únicas que ocorrem em todos os documentos do conjunto de treinamento.

O descritor do documento d é representado pela equação 4.1. Ela demonstra a probabilidade de ocorrência de cada palavra que compõe o dicionário. Sendo h o histograma de palavras, e c o número de palavras presentes no dicionário, temos:

$$Bow(d) = \frac{h(d)}{c(d)} \quad (4.1)$$

4.4 Treinamento

Para o treinamento do classificador, o algoritmo foi desenvolvido na linguagem de programação Python 3.5, e a *framework* TFLearn para o treinamento e avaliação dos modelos. A linguagem Python foi escolhida por possuir diversos módulos e plataformas que são voltadas para o PLN, como a NLTK.

O TFLearn é uma biblioteca de aprendizagem profunda modular e transparente construída sobre o Tensorflow. Ele foi projetado para fornecer uma API de nível superior ao TensorFlow para facilitar e agilizar as experimentações, mantendo-se totalmente transparente e compatível com ele (TFLEARN, 2018).

4.5 Experimentos e Resultados

Para a realização dos experimentos aqui descritos, utilizou-se um computador, com hardware composto por processador Intel Core I5 64 bits, 8GB de memória RAM DDR3,

memória de vídeo 2GB e placa de vídeo nvidia GeForce 930M.

4.5.1 Testes com Variações de Parâmetros no Pré-Processamento

Três tipos de especificações de pré-processamento foram aplicadas. Dentre as técnicas de pré-processamento existentes, foram escolhidas as seguintes, para realização dos testes: tokenização, remoção das palavras duplicadas e *stemming*. A tabela 7 demonstra a distribuição dos parâmetros.

Tabela 7 – Parâmetros Usados no Pré-Processamento

Pré-Processamento	Toquenização	Rem. Duplicadas	Stemming
PP1	X	X	X
PP2	X		X
PP3	X	X	
PP4	X		

Na configuração do pré-processamento PP1, todas as técnicas são aplicadas. No PP2, não são usados os métodos Remoção de palavras duplicadas. No PP3 é feito apenas o processo de tokenização e remoção das frases duplicadas. E por fim, na opção PP4, apenas a tokenização é utilizada.

4.5.2 Métricas

Para avaliar o desempenho de modelos de classificadores em PLN, geralmente são utilizadas as seguintes métricas: Acurácia (ACC), Recall, F1-score e Precisão. Essas métricas fazem uso da matriz de confusão, que indica a classificação correta ou incorreta das classes em uso, agrupando os resultados em quatro classes, sendo elas: Falso Negativo (FN), Falso Positivo (FP), Verdadeiro Positivo (VP) e Verdadeiro Negativo (VN).

4.5.2.1 Acurácia

A acurácia (ACC) calcula a proporção de acertos, ou seja, o total de verdadeiramente positivos e verdadeiramente negativos da amostra. Como demonstra a Equação (4.2)

$$Acuracia = \frac{VP + VN}{Total} \quad (4.2)$$

4.5.2.2 Recall

A métrica *Recall* é utilizada para indicar a relação entre as previsões positivas realizadas corretamente e todas as previsões que realmente são positivas. Como demonstra a Equação 4.3.

$$Precisao = \frac{VP}{VP + FN} \quad (4.3)$$

4.5.2.3 F1-score

Score F1 (F1)(também *F-score* ou *F-measure*) é uma medida da precisão de um teste. Considera tanto a precisão quanto a recordação do teste para calcular a pontuação. O escore F1 pode ser interpretado como uma média ponderada da precisão e da recordação, em que uma pontuação F1 atinge seu melhor valor em 1 e a pior pontuação em 0. A Equação (4.4), demonstra como essa métrica é calculada.

$$F1 = \frac{2 * precisao * recall}{precisao + recall} \quad (4.4)$$

4.5.2.4 Precisão

A Precisão é utilizada para indicar a relação entre as previsões positivas realizadas corretamente e todas as previsões positivas (incluindo as falsas). Tem a função de indicar a eficácia do método, conforme utilizado na Equação 4.5.

$$Precisao = \frac{VP}{VP + VN} \quad (4.5)$$

4.5.3 Resultados Obtidos

Essa seção mostra e discute os resultados obtidos com a metodologia proposta apresentando os resultados dos testes realizados a partir das análises dos dados.

Após avaliar a bibliografia encontrada a respeito do tema, foram encontrados diversos modelos de arquitetura compatíveis com a proposta desse trabalho, os quais foram comparadas e avaliadas para determinar qual a melhor performance dentro do objetivo do trabalho. Com isso, foi possível selecionar quatro principais modelos para estudo mais profundo e consequente avaliação da melhor performance. Os modelos escolhidos foram o DNN, MLP, LSTM e HNET, conforme visto no capítulo 2.

Tabela 8 – Especificação de PP1

Modelo	ACC (%)	Recall (%)	F1 (%)	Precisão (%)
DNN	98.30%	96.17%	97.24%	98.40%
MLP	95.01%	77.60%	77.23%	77.16%
LSTM	37.41%	23.50 %	11.13%	8.01%
HNET	95.68%	78.77%	76.82%	75.33%

Tabela 9 – Especificação de PP2

Modelo	ACC (%)	Recall (%)	F1 (%)	Precisão (%)
DNN	98.26%	95.63%	97.20%	98.04%
MLP	94.86%	77.60%	77.23%	77.16%
LSTM	36.43%	22.11%	10.22%	7.58%
HNET	95.61%	78.53%	76.77%	75.33%

Tabela 10 – Especificação de PP3

Modelo	ACC (%)	Recall (%)	F1 (%)	Precisão (%)
DNN	39.86%	23.80%	18.33%	33.68%
MLP	37.20%	20.01%	10.84%	7.44%
LSTM	34.23%	16.23%	9.77%	6.43%
HNET	36.07%	19.43%	9.21%	7.32%

Tabela 11 – Especificação de PP4

Modelo	ACC (%)	Recall (%)	F1 (%)	Precisão (%)
DNN	40.86%	24.42%	19.21%	33.75%
MLP	38.11%	22.35%	10.78%	7.20%
LSTM	37.03%	19,11%	9.87%	6.89%
HNET	37.83%	19.11%	10.14%	6.87%

Os valores presentes nas Tabelas 7, 8, 9 e 10 apresentam um resumo dos principais testes realizados, demonstrando o desempenho da metodologia utilizada para a classificação dos crimes contra a honra. Com base nos resultados obtidos, constata-se que a arquitetura DNN conseguiu os resultados mais promissores e equilibrados em todos os casos de testes na metodologia. Diante dos resultados experimentais apresentados, demonstra-se que o método proposto apresenta alto índice de precisão e que a fase de pré-processamento do texto tem impacto nesses resultados.

5 Conclusão

O principal objetivo desta pesquisa foi propor uma arquitetura para um classificador de crimes contra a honra, utilizando IA, focado na classificação de intenções e no reconhecimento de entidades, sem a necessidade de reconhecimento de padrões estáticos (padrões que necessitam ter uma relevância de 100% na combinação com a entrada), e que saibam reconhecer as similaridades entre os padrões conhecidos e a entrada do usuário, uma técnica muito utilizada no campo da IA.

Foi utilizado o *Deep Learning*, que é uma subárea da Inteligência Artificial que está em crescente avanço, inovando com o surgimento em aplicações de diversas técnicas e usos, impulsionando uma nova era de automatização inteligente. Com o uso de técnicas de PLN e IA, esse trabalho apresentou uma metodologia para classificação automática de crimes contra a honra, utilizando a biblioteca NTLK para o PLN e o classificador DNN para classificação dos crimes contra a honra.

Desta forma, este trabalho apresenta contribuições na área jurídica, oferecendo uma metodologia automática para auxílio na classificação de crimes contra a honra, e para a computação, na adaptação de técnicas de outras áreas do conhecimento, adequando-as especificamente, na área do processamento de linguagem natural aos meios e técnicas de classificação já existentes.

Como trabalhos futuros, pretende-se:

- Uso de um *crawler* para coleta personalizada de sentenças para aumentar a base de dados, e assim enriquecer o classificador desenvolvido.
- Implementar integrações com o *Telegram*, *Slack* ou *Facebook Messenger*.
- Validação do modelo por especialistas.

Referências

- BANERJEE, I. et al. Comparative effectiveness of convolutional neural network (cnn) and recurrent neural network (rnn) architectures for radiology text report classification. *Artificial intelligence in medicine*, Elsevier, 2018. Citado 2 vezes nas páginas 26 e 27.
- BRITO, G. da S. Lingüistas e computadores: que relação é essa? *Working Papers em Linguística*, v. 4, n. 1, p. 7–23, 2000. Citado na página 20.
- CARVALHO, H. V. de et al. Detecção de anomalias em comportamento de abelhas utilizando redes neurais recorrentes. In: SBC. *9º Workshop de Computação Aplicada a Gestão do Meio Ambiente e Recursos Naturais (WCAMA_CSBC 2018)*. [S.l.], 2018. v. 9. Citado na página 25.
- CORREA, F. C. J. *Crimes Contra a Honra na internet*. [S.l.], 2015. Disponível em: <<https://flaviacristinajcorrea.jusbrasil.com.br/artigos/206759390/crimes-contr-a-honra-nas-redes-sociais>>. Acesso em: 26 mar. 2018. Citado na página 14.
- CURY, C. F. C. et al. Expert systems: Evolution, importance and applicability through software development, cargoapp. In: . [S.l.: s.n.], 2018. Citado na página 19.
- CUTTLE, J. A. T. et al. Utilização de redes convolucionais profundas para estimativa de ângulos de pose de fâcies obtidas através do kinect®. Florianópolis, SC., 2018. Citado na página 22.
- FERNANDES, M. S. Análise de textos parlamentares. 2016. Citado na página 22.
- GAMBÄCK, B.; SIKDAR, U. K. Using convolutional neural networks to classify hate-speech. In: *Proceedings of the first workshop on abusive language online*. [S.l.: s.n.], 2017. p. 85–90. Citado na página 27.
- GUIMARÃES, A. M. et al. Módulo de validação cruzada para treinamento de redes neurais artificiais com algoritmos backpropagation e resilient propagation. *Publicatio UEPG–Ciências exatas e da terra, ciências agrárias e engenharias*, v. 1, p. 17–24, 2008. Citado na página 22.
- HAN, J. et al. Analysis of criminal case judgment documents based on deep learning. In: ATLANTIS PRESS. *2018 International Conference on Advanced Control, Automation and Artificial Intelligence (ACAAI 2018)*. [S.l.], 2018. Citado 2 vezes nas páginas 26 e 27.
- HE, B.; GUAN, Y.; DAI, R. Classifying medical relations in clinical text via convolutional neural networks. *Artificial intelligence in medicine*, Elsevier, v. 93, p. 43–49, 2019. Citado 2 vezes nas páginas 26 e 27.
- LORENCI, I. C. de. Dos crimes contra a honra - reflexão. UNESC, 2002. Citado na página 16.
- MARQUES, A. N. G. Direito À honra. *TRIBUNAL DE JUSTIÇA DO DISTRITO FEDERAL E DOS TERRITÓRIOS*, v. 1, n. 1, p. 5, 2010. Citado na página 16.

- MONIKA, P.; VENKATESAN, D. Di-ann clustering algorithm for pruning in mlp neural network. *Indian Journal of Science and Technology*, Indian Society for Education and Environment, v. 8, n. 16, p. 1, 2015. Citado na página 24.
- MULLER, D. N. Comfala: modelo computacional do processo de compreensão da fala. 2006. Citado na página 20.
- NETO, J. A. C. et al. Inteligência artificial: Um estudo guiado por patentes. *Instituto Federal de Sergipe – IFS*, 2018. Citado na página 20.
- NLTK. *Kit de Ferramentas de Linguagem Natural*. [S.l.], 2018. Disponível em: <<https://www.nltk.org/>>. Acesso em: 04 mar. 2019. Citado na página 30.
- NUNES, F. P. C. Disorderclassifier: classificação de texto para categorização de transtornos mentais. Universidade Federal de Pernambuco, 2016. Citado na página 29.
- OLIVEIRA, A. C. de et al. Estudos de inteligência artificial usando computadores quânticos. 2013. Citado na página 19.
- PATRÍCIO, D. I. et al. Seedflow: Sistema de visão computacional para classificação de grãos de aveia. Universidade de Passo Fundo, 2019. Citado na página 23.
- PEREIRA, A. A. *O que são os crimes contra a honra?* [S.l.], 2016. Disponível em: <<https://juridicocerto.com/p/andrearnaldopereira/artigos/o-que-sao-os-crimes-contra-a-honra-3027>>. Acesso em: 1 mai. 2018. Citado na página 18.
- PEREIRA, A. M.; GOMES, M.; FÁVERO, N. C. A inteligência artificial utilizada na recuperação de informações. *Revista Eletrônica de Sistemas de Informação e de Gestão Tecnológica*, v. 1, n. 1, 2011. Citado na página 19.
- PINEDA, A. L. et al. Deep learning facilitates rapid classification of human and veterinary clinical narratives. *bioRxiv*, Cold Spring Harbor Laboratory, p. 429720, 2019. Citado 2 vezes nas páginas 26 e 27.
- PRASS, R. *Como agir em casos de ofensa na internet*. [S.l.], 2014. Disponível em: <<https://g1.globo.com/tecnologia/blog/tira-duvidas-de-tecnologia/post/como-agir-em-casos-de-ofensa-na-internet.html>>. Acesso em: 26 mar. 2018. Citado na página 14.
- RANGEL, D. C. Você sabe a diferença entre os crimes de calúnia, difamação e injúria? Jus, 2015. Citado na página 18.
- ROCHA, R. H. S. *Reconhecimento de Objetos por Redes Neurais Convolutivas*. Tese (Doutorado) — PUC–Rio, 2015. Citado na página 24.
- SBOEV, A. et al. Deep learning network models to categorize texts according to author’s gender and to identify text sentiment. In: IEEE. *2016 International Conference on Computational Science and Computational Intelligence (CSCI)*. [S.l.], 2016. p. 1101–1106. Citado na página 27.
- SILVA, J. R. da. *O que é o Processamento de Linguagem Natural?* [S.l.], 2017. Disponível em: <<https://medium.com/botsbrasil/o-que-%C3%A9-o-processamento-de-linguagem-natural-49ece9371cff>>. Acesso em: 2 mai. 2018. Citado 2 vezes nas páginas 20 e 21.

- SOARES, F. de A. *Mineração de Textos na Coleta Inteligente de Dados na Web*. Tese (Doutorado) — PUC-Rio, 2008. Citado na página 21.
- TAMBOSI, T. L. *Crimes Contra a Honra na internet*. [S.l.], 2016. Disponível em: <https://repositorio.ufsc.br/bitstream/handle/123456789/166574/TCC_V-.pdf?sequence=1&isAllowed=y>. Acesso em: 26 mar. 2018. Citado na página 14.
- TFLEARN. *TFLearn*. [S.l.], 2018. Disponível em: <<http://tflearn.org/>>. Acesso em: 04 mar. 2019. Citado na página 30.
- UNDAVIA SAMIR, M. A. O. J. E. A comparative study of classifying legal documents with neural networks. In: IEEE. *2018 Federated Conference on Computer Science and Information Systems (FedCSIS)*. [S.l.], 2018. p. 515–522. Citado 2 vezes nas páginas 26 e 27.
- XING, C.; XU, L.; WANG, P. Kgcnn: A new cnn with keywords group for crime classification over legal articles. In: IEEE. *2018 IEEE 9th International Conference on Software Engineering and Service Science (ICSESS)*. [S.l.], 2018. p. 788–792. Citado 2 vezes nas páginas 26 e 27.
- YAO, H. et al. Revisiting spatial-temporal similarity: A deep learning framework for traffic prediction. In: *2019 AAAI Conference on Artificial Intelligence (AAAI'19)*. [S.l.: s.n.], 2019. Citado na página 25.



**TERMO DE AUTORIZAÇÃO PARA PUBLICAÇÃO DIGITAL NA BIBLIOTECA
“JOSÉ ALBANO DE MACEDO”**

Identificação do Tipo de Documento

- () Tese
() Dissertação
(X) Monografia
() Artigo

Eu **Artur Pereira da Silva**, autorizo com base na Lei Federal nº 9.610 de 19 de Fevereiro de 1998 e na Lei nº 10.973 de 02 de dezembro de 2004, a biblioteca da Universidade Federal do Piauí a divulgar, gratuitamente, sem ressarcimento de direitos autorais, o texto integral da publicação ***HonorisClassifier: Classificador de Crimes Contra a Honra*** de minha autoria, em formato PDF, para fins de leitura e/ou impressão, pela internet a título de divulgação da produção científica gerada pela Universidade.

Picos-PI 14 de Agosto de 2019.

Artur Pereira da Silva
Assinatura