



Trabalho de Conclusão de Curso

**Um estudo comparativo entre técnicas de
aprendizado de máquina para classificação
de intenções, em um contexto de diálogos no
e-commerce de roupa**

Gabriel Barbosa Pereira
gbp@ic.ufal.br

Orientador:
Prof. Dr. Evandro de Barros Costa

Co-orientador:
Prof. Dr. Thales Vieira

Maceió, Dezembro de 2022

Gabriel Barbosa Pereira

**Um estudo comparativo entre técnicas de
aprendizado de máquina para classificação
de intenções, em um contexto de diálogos no
e-commerce de roupa**

Monografia apresentada como requisito parcial
para obtenção do grau de Bacharel em Ciência
da Computação do Instituto de Computação da
Universidade Federal de Alagoas.

Orientador:

Prof. Dr. Evandro de Barros Costa

Co-orientador:

Prof. Dr. Thales Vieira

Maceió, Dezembro de 2022

Catálogo na fonte
Universidade Federal de Alagoas
Biblioteca Central
Divisão de Tratamento Técnico
Bibliotecária: Taciana Sousa dos Santos – CRB-4 – 2062

P436e Pereira, Gabriel Barbosa.

Um estudo comparativo entre técnicas de aprendizado de máquina para classificação de intenções, em um contexto de diálogos no e-commerce de roupa / Gabriel Barbosa Pereira. – 2022.

85 f. : il. color.

Orientador: Evandro de Barros Costa.

Coorientador: Thales Vieira.

Monografia (Trabalho de Conclusão de Curso em Ciência da Computação) – Universidade Federal de Alagoas. Instituto de Computação. Maceió, 2022.

Bibliografia: f. 81-85.

1. Chatbots. 2. E-commerce. 3. Classificação de intenção. 4. Aprendizagem de máquina. I. Título.

CDU: 004.8

Agradecimentos

Primeiramente à Deus por sempre guiar o meu caminho.

A minha família, por sempre estar tão presente, dando todo o suporte necessário em minha vida pessoal, acadêmica e profissional, e me incentivando a buscar sempre mais. Em especial aos meus pais Joseildo e Telma que com seu sacrifício fizeram com que tudo isso fosse possível.

À minha namorada Raylene Souza, por caminhar ao meu lado durante todos anos que passei na graduação, pelo seu apoio, companheirismo e incentivo.

A todos os meus amigos, sobretudo os meus companheiros de graduação, Daniel Vas-salo, França Mac Dowell, Lucas Amorim, Lucas Raggi, Nelson Gomes e Wagner Fontes, com quem pude aprender muito e compartilhar dos momentos alegres e dos desafios dessa jornada.

Aos meus professores que se dedicaram durante toda a graduação para que eu tivesse o melhor em termos de ensino e que sempre exigiram que eu desse o meu máximo du-rante minha formação, principalmente meu orientador Evandro de Barros Costa e meu co-orientador Thales Vieira, que foram essenciais para o desenvolvimento deste trabalho e da minha formação acadêmica e profissional.

“The secret of getting ahead is getting started.”

– Mark Twain

*“ ...se você tivesse uma chance, ou uma oportunidade para ter tudo o que
você sempre quis... um momento... você pegaria, ou deixaria escapar? ”*

– Eminem, Lose Yourself

Resumo

Ao longo dos últimos anos é perceptível como os agentes de conversação, tais como os chatbots e os assistentes virtuais, foram cada vez mais integrados na vida do ser humano. Ao analisarmos especificamente o setor de e-commerce, é possível ver como esse tipo de tecnologia está realmente incorporada ao mesmo, trazendo benefícios para o usuário final. Com o passar do tempo essas tecnologias foram evoluindo e graças a inteligência artificial, o processo de entrega de valor foi sendo refinado. A classificação de intenções é uma das etapas mais importantes na construção de um agente de conversação moderno. Através do classificador de intenções, o chatbot consegue identificar e classificar automaticamente cada enunciado inserido pelo usuário em intenções, gerando conhecimento de valor. Este trabalho propõe uma abordagem de um classificador de intenções para enunciados em um diálogo no contexto do e-commerce de moda. Para atingir o objetivo, foi realizado um estudo comparativo entre vários modelos de aprendizado de máquina comumente utilizados para essa finalidade. Resultados indicaram que o modelo de aprendizado de máquina SVC é o que demonstra melhor desempenho frente a outros modelos na classificação de intenções para diálogos no e-commerce de roupa.

Palavras-chave: Classificador de intenções; Chatbots; Aprendizado de máquina; E-commerce de moda.

Abstract

Over the past years, it has been noticeable how conversational agents, such as chatbots and virtual assistants, have been increasingly integrated into human life. By explicitly analyzing the e-commerce sector, it is possible to see how this type of technology is incorporated, bringing benefits to the final user. Over time these technologies have evolved and thanks to artificial intelligence, the process of generating value has been refined. Intent classification is one of the most important steps in building a modern conversational agent. Through the intent classifier, the chatbot can automatically identify and classify each statement entered by the user into intents, generating valuable knowledge. This work proposes an intention classifier approach for utterances in a dialogue in the context of fashion e-commerce. To achieve the objective, a comparative study was carried out between several machine learning models commonly used for this purpose. Results indicated that the SVC machine learning model is the one that demonstrates the best performance compared to other models in the classification of intentions for dialogues in e-commerce clothing.

Keywords: Intent classifier; Chatbots; Machine learning; Fashion e-commerce.

Lista de Figuras

2.1	Linha do tempo da evolução dos chatbots	19
2.2	Esboço simplificado do algoritmo utilizado pelo chatbot ELIZA	22
2.3	Os três V's do <i>Big Data</i>	24
2.4	Infográfico demonstrando a diferença entre intenções e entidades para um chatbot	29
2.5	Arquitetura simplificada de um chatbot	30
2.6	Esquema da classificação de intenções e da extração de entidades utilizando o processamento de linguagem natural do software Rasa	31
3.1	Tela do sistema desenvolvido na perspectiva de um lojista mostrando o catálogo do estoque disponível	39
4.1	Arquitetura original da LSTM	42
4.2	Ilustração do <i>dataset</i> SIMMC 2	44
4.3	Demonstração de uso do classificador de intenções desenvolvido	53
4.4	Captura de tela do site oficial da loja virtual My Trend	57

Lista de Tabelas

4.1	Resultados obtidos utilizando o modelo LSTM e a base de dados SIMMC ordenados pela acurácia	45
4.2	Resultados obtidos utilizando o modelo LSTM e a base de dados SIMMC 2 ordenados pela acurácia	45
4.3	Tabela com a matriz de confusão para o modelo LSTM com melhor resultado de acurácia dentre as duas bases de dados	46
4.4	Resultados obtidos utilizando o modelo BiLSTM e a base de dados SIMMC ordenados pela acurácia	46
4.5	Resultados obtidos utilizando o modelo BiLSTM e a base de dados SIMMC 2 ordenados pela acurácia	47
4.6	Tabela com a matriz de confusão para o modelo BiLSTM com melhor resultado de acurácia dentre as duas bases	47
4.7	Resultados obtidos utilizando o modelo Bert e a base de dados SIMMC ordenados pela acurácia	48
4.8	Resultados obtidos utilizando o modelo Bert e a base de dados SIMMC 2 ordenados pela acurácia	48
4.9	Tabela com a matriz de confusão para o modelo Bert com melhor resultado de acurácia dentre as duas bases	48
4.10	Resultados obtidos utilizando o modelo SVC e a base de dados SIMMC ordenados pela acurácia	50
4.11	Resultados obtidos utilizando o modelo SVC e a base de dados SIMMC 2 ordenados pela acurácia	51
4.12	Tabela com a matriz de confusão para o modelo SVC com melhor resultado de acurácia dentre as duas bases	52
4.13	Comparativo da acurácia do modelo SVC utilizando a técnica “Word to Vector”	52
4.14	Tabela com melhor resultado para cada modelo utilizando as duas bases ordenada pela acurácia	53
4.15	5 ações mais recorrentes nas frases extraídas da simulação 1	54
4.16	5 ações mais recorrentes nas frases extraídas da simulação 2	55
4.17	Quantidade de sentenças coletadas através dos experimentos por intenção .	56

4.18	Quantidade de sentenças coletadas no WhatsApp classificadas por intenção	57
4.19	Quantidade de sentenças coletadas no Instagram classificadas por intenção	58
4.20	Quantidade de sentenças coletadas classificadas por intenção	58

Conteúdo

Lista de Figuras	vii
Lista de Tabelas	ix
1 Introdução	12
1.1 Motivação e Contextualização	12
1.2 Objetivos	13
1.3 Estrutura do trabalho	13
2 Fundamentação Teórica	15
2.1 Introdução ao estudo de linguagem natural	15
2.2 Introdução aos sistemas de conversação	16
2.2.1 História e evolução dos chatbots	17
2.2.2 Atual desenvolvimento dos chatbots	20
2.2.3 Categorização dos chatbots	21
2.3 Chatbots e e-services	23
2.4 Introdução a Big Data	24
2.5 Coleta de dados e formação de corpora	25
2.6 Privacidade e anonimização dos dados	26
2.7 Intenções e entidades	27
2.7.1 Tipos de intenções	29
2.7.2 Classificação de intenções	30
2.8 Introdução ao aprendizado de máquina	32
2.8.1 Redes neurais e aprendizagem profunda	33
3 Metodologia	34
3.1 Estudo teórico	35
3.2 Estudo comparativo entre técnicas de aprendizado de máquina para clas- sificação de intenções	35
3.2.1 Pesquisa bibliográfica	35
3.2.2 Estudo comparativo	36
3.3 Coleta de dados e criação de um dataset	37
3.3.1 Chat para simulação de conversas entre lojistas e clientes	38

3.3.2	Coleta de dados reais	39
3.3.3	Categorização dos dados gerados e formação de corpora	39
4	Resultados e Discussões	41
4.1	Estudo comparativo	41
4.1.1	Escolha dos modelos de aprendizado de máquina	41
4.1.2	Escolha das bases de dados	43
4.1.3	Análise dos modelos de aprendizado de máquina escolhidos	44
4.2	Criação de um dataset	54
4.2.1	Estudo acerca da formação de corpora	54
4.2.2	Simulação de conversa entre lojista e cliente	54
4.2.3	Coleta de dados reais	56
4.2.4	Formação do corpora com os dados coletados	58
5	Conclusões	59
5.1	Considerações Finais	59
5.2	Trabalhos futuros	60
A	Base de dados gerada através do trabalho desenvolvido	61
	Referências bibliográficas	81

1

Introdução

1.1 Motivação e Contextualização

Os agentes de conversação como os chatbots e os assistentes virtuais são ferramentas que estão cada vez mais presentes no dia a dia da sociedade contemporânea. Em 2021, cerca de 1,4 bilhão de pessoas usaram chatbots em todo o mundo, e os 5 principais países que usam chatbots são os Estados Unidos, a Índia, Alemanha, Reino Unido e Brasil ([Outgrow, 2021](#)). Segundo estimativas, mais de 67% dos consumidores em todo o mundo usaram um chatbot para suporte ao cliente em 2019 ([Invesp, 2019](#)).

Quando se fala especificamente do e-commerce, vê-se como a integração destes agentes nos websites e nas mídias sociais tem sido cada vez mais adotada trazendo benefícios para o cliente e para o comerciante, alguns desses benefícios são: o atendimento instantâneo, as sugestões automáticas de compras, o maior engajamento com o cliente, entre outros. Os chatbots podem economizar até 30% no custo de suporte ao cliente e podem ajudar as empresas a acelerar os tempos de resposta, respondendo a até 80% das perguntas de rotina ([Invesp, 2019](#)).

No contexto de uma conversação, a classificação de intenções tornou-se uma tarefa essencial para o bom funcionamento de um chatbot, através dela acontece a identificação do desejo do usuário e consequentemente a formulação da resposta apropriada que deve ser retornada pelo sistema. De acordo com [Schuurmans and Frasincar \(2020\)](#) a classificação de intenções tenta responder o por que o cliente contatou a empresa em primeiro lugar e o que o cliente quer alcançar através desse contato. Para que isso aconteça, é primordial que haja uma base de dados e um modelo de dados alinhados com o domínio em que o chatbot será empregado.

Entretanto, mesmo com muitos avanços na área do processamento de linguagem natural e na construção de bases de dados sólidas, é frequente que para muitos domínios,

poucos dados para treinamento desses sistemas e poucos estudos acerca dos mesmos estejam disponíveis.

Para que a evolução dos agentes de conversação e sua difusão na sociedade continue de forma constante é prático que haja a criação de métodos alternativos para coleta de dados e avaliações comparativas entre os modelos de inteligência artificial já comumente utilizados para esse propósito.

Os problemas que direcionam o presente estudo estão ligados à preparação de dados e à viabilização de diálogo de chatbot com usuários, considerando os dados representados. Assim, para contribuir com soluções as partes desses problemas, este trabalho propõe o desenvolvimento de um classificador de intenções, bem como a elaboração de uma base de dados em português com enunciados de conversas do e-commerce de moda como será especificado na próxima seção.

1.2 Objetivos

Este trabalho tem como objetivo primário um estudo sobre vários modelos de aprendizado de máquina a fim de se propor uma abordagem para a problemática da classificação de intenções para enunciados em um diálogo no contexto do e-commerce de moda. Como objetivo secundário tem-se ainda a criação e disponibilização de um conjunto de dados em português de enunciados retirados de diálogos também ligados ao e-commerce.

1.3 Estrutura do trabalho

Esta seção é dedicada a mostrar a organização desta monografia que foi dividida em 5 capítulos e um anexo, sendo esta seção parte do primeiro capítulo, que é dedicado a introdução do trabalho proposto.

No capítulo 2 é apresentado alguns dos principais conceitos e teorias disponíveis na literatura a serem utilizados durante o desenvolvimento do trabalho. Foram abordados conteúdos acerca de inteligência artificial, aprendizagem de máquina, estudo de linguagem natural, desenvolvimento de chatbots entre outros assuntos pertinentes que serviram de base para o restante das atividades executadas.

O capítulo 3 apresenta a metodologia do trabalho proposto, ou seja, quais procedimentos e operações foram realizadas a fim de se chegar nos resultados explicados no capítulo 4. Em mais detalhes, no capítulo 3 é explicado como se deu o estudo teórico e em que o mesmo foi focado, também é explicada a metodologia utilizada para realização dos experimentos e para a coleta dos dados assim como é explicado o método utilizado para desenvolvimento do classificador de intenções

Já o capítulo 4 como citado anteriormente, apresenta todos os resultados obtidos

em todas as etapas citadas anteriormente. São mostrados com mais detalhes os dados coletados para a formação do dataset de conversas no contexto de e-commerce assim como também é mostrado, de forma detalhada, o classificador de intenções desenvolvido.

Por fim, no capítulo 5 apresentamos as considerações finais, apresentando as conclusões sobre o trabalho desenvolvido, os resultados e contribuições, bem como algumas limitações e apontamento de trabalhos futuros. Logo em seguida temos o apêndice que contém o dataset formado pelos dados coletados.

2

Fundamentação Teórica

Neste capítulo será apresentada uma visão geral sobre alguns assuntos relacionados ao presente trabalho, incluindo-se: agentes de conversação e chatbot usando linguagem natural.

2.1 Introdução ao estudo de linguagem natural

Linguagem natural é a linguagem utilizada pelo ser humano para comunicação, que pode ser tanto escrita quanto falada e se distingue de uma linguagem formal, a exemplo de uma linguagem de programação (Python, C, Java, entre outras), devido principalmente aos fatos de serem repletas de regras e ambiguidades que dependem exclusivamente do idioma e do ambiente em que é utilizada.

Daí surge o principal desafio do estudo da linguagem natural, que é fazer com que a tecnologia consiga entender e interpretar o real significado da linguagem humana de acordo com os parâmetros de uma linguagem formal (utilizada nos computadores). E para isso, surgiu o ramo dentro da inteligência artificial focado apenas em entender e processar essa linguagem, o Processamento de Linguagem Natural (PLN), ou, *Natural Language Processing* (NLP), em inglês.

Segundo [Goyal et al. \(2018\)](#), processamento de linguagem natural, de forma simplificada, é a habilidade de um computador ou sistema, entender verdadeiramente a linguagem humana e desta forma, processá-la do mesmo modo que os humanos fazem. E como já dito anteriormente, não é uma tarefa fácil, devido as regras e peculiaridades de cada idioma e também porque em uma conversa entre humanos, há muito significado no que não é dito, como na postura corporal, nas expressões, entonação e até mesmo o silêncio representa algo em uma conversa.

Além do desafio de entender a linguagem humana, ainda tem o desafio de gerar uma resposta ao texto de entrada feito pelo usuário, ou seja, de acordo com o que o usuário

escrever ou falar, responder de forma que faça sentido semanticamente e sintaticamente, lidando muitas vezes até mesmo com conceitos abstratos, tais como sentimentos.

Dentro da área de processamento de linguagem natural, há duas principais sub-áreas, são elas a NLU ou *Natural Language Understanding* (em português, compreensão de linguagem natural) e a NLG - *Natural Language Generation*, que em português se traduz como geração de linguagem natural. Sendo que a primeira cuida de coisas como análise de sentimento, detecção de entidades e intenções, etc., e a segunda, da geração de respostas apropriadas ao que foi interpretado dentro do motor de processamento de texto e até mesmo geração de texto complementar para uso em treinamento de modelos de NLP.

Várias aplicações utilizam do processamento de linguagem natural, tais como o mecanismo de busca do Google (Kopp, 2022), que precisa analisar as entradas cedidas pelos usuários e assim entregar os resultados mais relevantes daquela pesquisa, e até mesmo realizar o processamento das pesquisas realizadas por voz, há também os assistentes pessoais virtuais, como a Siri ou o Google Assistant, que processam os comandos dos usuários e retornam exatamente o que foi pedido, e é claro, há também os chatbots, ou sistemas de conversação, que precisam analisar as entradas e assim retornar uma saída apropriada.

Importante salientar que modelos de processamento da linguagem natural demandam muitas vezes de grandes quantidades de dados para o treinamento a depender da tarefa ao qual estão encarregados e quais habilidades são exigidas dos mesmos (Zhang et al., 2020), com isso, várias tecnologias foram criadas e estão sendo desenvolvidas para a coleta de dados e desenvolvimento desses modelos (Hrkút et al., 2020). O NLTK, o Gensim, o Pattern, o SpaCy e o TextBlob por exemplo, são algumas das principais bibliotecas de NLP utilizadas e escritas na linguagem de programação Python.

2.2 Introdução aos sistemas de conversação

Um chatbot ou chatterbot, de forma simplificada, é um programa de computador projetado para realizar uma comunicação inteligente (normalmente com humanos), através de uma tela de bate-papo, tanto no campo textual quanto no campo oral. Este programa de computador está incubido de processar uma entrada em linguagem natural de um usuário e gerar respostas relativas àquela entrada, de volta para o usuário.

Alguns autores como Jurafsky and Martin (2019) e Mctear (2004), categorizam os sistemas de conversação em dois tipos: os chatbots e os sistemas de diálogos. Onde, os sistemas de diálogo são criados para uso em um domínio específico, orientados a uma tarefa em particular, enquanto os chatbots ou sistemas de conversação simulada são desenvolvidos para uso em domínio aberto. Masche and Le (2018) mostra em seu artigo que o sistema de diálogo requer normalmente o uso de quatro componentes, sendo estes um componente de pré-processamento, um de entendimento de linguagem natural, um ge-

renciador de diálogo e um componente de geração de respostas, enquanto os chatbots são construídos através de uma base de conhecimento com um algoritmo de reconhecimento de padrões seguindo o fluxo entrada-reposta.

Estas duas definições a respeito dos sistemas de conversação se confundem já que essas duas categorias não são claramente definidas. O que difere cada uma dessas categorias pode facilmente ser aplicada a outra sem prejuízo do conceito ou objetivo final do sistema desenvolvido, por exemplo, um chatbot pode ter um componente de geração de resposta assim como ter um módulo de entendimento de linguagem natural e ainda sim ser considerado um chatbot por ter um domínio aberto. Neste trabalho, para todos os fins, ambos os termos são aplicados aos sistemas de conversação, não tendo diferença de significado.

2.2.1 História e evolução dos chatbots

A história dos chatbots começa em 1950 com um polímata inglês chamado Alan Mathison Turing, em um mundo ainda em recuperação da II Guerra Mundial. Turing desenvolveu um teste para analisar se uma pessoa conseguiria distinguir uma máquina de um humano, ou seja, se uma máquina seria capaz de exibir um comportamento suficientemente inteligente para ser equivalente a um ser humano, este teste é conhecido até os dias atuais como teste de [Turing \(1950\)](#).

Em 1966, dezesseis anos após o teste de Turing ser criado, o programa de computador ELIZA surgiu. Inventado por Joseph Weizenbaum ([Weizenbaum, 1966](#)) no laboratório de Inteligência Artificial do MIT, ELIZA com cerca de 200 linhas de código tentava imitar a fala dos psicoterapeutas analisando as palavras chave inseridas pelo usuário e acionando as regras de transformação para gerar uma saída (uma pergunta ou uma resposta), por exemplo, ao declarar uma sentença que contenha a palavra 'eu', ELIZA mudaria essa palavra para 'você' na resposta, a palavra 'meu' mudaria para 'seu' e assim por diante, vale ressaltar que esta metodologia de geração de respostas ainda é utilizada no desenvolvimento de chatbots atualmente. E embora a ELIZA não tenha passado no teste de Turing, ela está marcada na história como o primeiro software de conversação do mundo. ELIZA está ainda disponível no site [Wallace \(1999\)](#).

Após a criação da ELIZA, vários chatbots foram desenvolvidos, em 1972, o psiquiatra americano Kenneth Colby criou o PARRY, um chatbot que tentava imitar um paciente com esquizofrenia. O PARRY era um sistema que funcionava através de suposições e respostas desencadeadas pela alteração de pesos atribuídos às entradas verbais. Em 1988, surgiu o Jabberwacky, desenvolvido pelo programador britânico Rollo Carpenter com o propósito de simular uma conversa humana e aprender através das mesmas (armazenava todas as conversas com a finalidade de encontrar as melhores respostas), este utilizava uma técnica de IA chamada "correspondência de padrões contextuais", lançada em 1997 e ganhou o primeiro lugar na competição Loebner nos anos 2005 e 2006 ([Carpenter and](#)

[Freeman, 2005](#)). Já em 1992, criado pelo Creative labs em Cingapura especificamente para computadores pessoais MS-Dos, o Dr.Sbaitso é um chatbot reconhecido por realizar um bate-papo por voz que simulava um psicólogo.

A.L.I.C.E., também chamada de Alicebot é um chatbot que simula uma pessoa real do sexo feminino, tendo ELIZA como inspiração foi desenvolvida em 1995 por Richard Wallace e embora assim como seus antecessores, não tenha passado no teste de Turing, recebeu o prêmio Loebner por três vezes seguidas, tornando-se assim uma referência na área. Alicebot foi construída utilizando um esquema com XML conhecido como AIML (Artificial Intelligence Markup Language) e desde 2001, quando Wallace tornou pública a especificação do AIML, desenvolvedores do mundo todo tem elaborado códigos open source da A.L.I.C.E. em diferentes idiomas e linguagens de programação.

No início do século 21, o SmartChild foi criado pela ActiveBuddy e foi a primeira tentativa de criar um chatbot que fornecesse mais que apenas entretenimento, mas que pudesse fornecer outros tipos de informações como placares de jogos, informações sobre ações e muito mais. Este chatbot era disponível dentro do AOL IM e no Windows Live Messenger (MSN Messenger), com mais de 30 milhões de pessoas usando-o. Em 2007 a Microsoft o comprou por 46 milhões de dólares. O SmarterChild foi o precursor da Siri e do S Voice, chatbots da Apple e Samsung respectivamente ([Khan and Das, 2018](#)).

A Siri é um assistente pessoal inteligente desenvolvido em 2010 pela SRI International e implantada pela Apple no sistema operacional IOS 5 para iPhones, a partir daí se tornou parte integral do sistema IOS. Siri foi o primeiro assistente inteligente após o início da era dos smartphones e provia muitas informações úteis sobre tempo, preço de ingresso de filmes e sobre ações por exemplo. Outras empresas como a Google e a Samsung seguiram os passos da Apple e criaram seus próprios assistentes inteligentes, foi o caso do Google Allo e do S Voice respectivamente.

Após a Siri, outras grandes empresas da tecnologia seguiram os passos da Apple e criaram seus próprios assistentes inteligentes, como é o caso do Google Now, lançado em 2012 pela Google, que respondia questões, fazia recomendações, realizava ações requisitadas pelos usuários e hoje em dia até fornece um sistema de pesquisa preditiva. Também foi o caso da Cortana, desenvolvida em 2014 pela Microsoft e integrada nos telefones Windows e também nos computadores pessoais com o sistema operacional Windows 10.

Mais recentemente, também houve o lançamento dos assistentes domésticos que respondiam à comandos por voz como o Amazon Alexa e o Google Home, lançados em 2015 e 2016 respectivamente, e que também são outra representação de chatbots. A figura abaixo mostra uma visualização completa da linha do tempo com os principais marcos do desenvolvimento e da evolução dos chatbots.




Figura 2.1: Linha do tempo da evolução dos chatbots

Fonte: (Khan and Das, 2017)

Cada vez mais, os cientistas de dados e desenvolvedores de aprendizagem de máquina têm trabalhado intensivamente na evolução dos chatbots, e cada vez mais, através do estudo e interpretação de linguagem natural, os sistemas de conversação se tornam melhor, entendem mais e aprendem da melhor maneira possível com o tempo. Grandes corporações como a Apple, o Facebook, o Google e a Microsoft investem grandes recursos em pesquisas na tentativa de imitação de conversas da vida real entre consumidores e máquinas visando fins comerciais.

Em 2014, o software Eugene Goostman passou no teste de Turing ao convencer 1/3 dos usuários participantes do teste, de que era uma criança de 13 anos. Eugene Goostman foi criado pelo pesquisador russo Vladimir Veselov e pelo pesquisador ucraniano Eugene Demchenko. E embora sob algumas críticas de como o teste foi realizado e apresentado,

o fato é que Eugene é um grande marco na história.

Atualmente os sistemas computacionais de conversação tem surgido em muitos domínios tais como o educacional, de suporte ou assistência, o de cuidados com a saúde, em indústrias e empresas (principalmente para o propósito de marketing) e até em jogos eletrônicos. E com a abertura da plataforma de robôs do Telegram em Junho de 2015, seguido pela implantação de usuários robôs em sistemas como o Slack, Skype e o We-Chat é possível ver a popularização dos chatbots, de fato, ao compararmos a jornada dos chatbots desde 1966 até agora, vemos que o que naquela época era apenas um sonho, se tornou real e conversar com agentes virtuais que não são humanos se tornou algo normal e cotidiano na vida das pessoas.

Hoje em dia, o desenvolvimento dos chatbots se dá a partir do estudo de técnicas mais avançadas de processamento textual como o processamento de linguagem natural, técnicas de compreensão de linguagem natural e técnicas de geração de linguagem natural, já citadas anteriormente, que são aplicadas com uma variedade de técnicas como correspondência de padrões baseada em regras (rule-based pattern matching), web semântica, mineração de texto e técnicas de aprendizagem profunda (Jeong and Seo, 2019).

Quanto mais dados disponíveis e de ótima qualidade para essas técnicas, como as que usam NLP e deep learning, melhores são os resultados, já que são métodos que precisam de uma quantidade grande de dados para que gerem um resultado minimamente aceitável, enfatizando a importância da coleta e preparação dos dados como fator indicativo de qualidade dos sistemas de conversação.

2.2.2 Atual desenvolvimento dos chatbots

Ao analisar-se a história, é possível perceber que de forma geral, as empresas sempre buscaram construir seus próprios sistemas de conversação de maneira isolada, para uso em sua plataforma, para servir às suas próprias necessidades e seus próprios usuários. Desde que empresas como o Telegram, o Slack e o Facebook abriram suas plataformas de criação de bots para uso em diversos tipos de serviços houve uma mudança neste paradigma.

Para dar suporte a criação de chatbots em tantas plataformas e serviços existentes, várias ferramentas que auxiliam o desenvolvedor a construir seu próprio sistema de diálogo foram criadas, tais como o Botframework da Microsoft, o ManyChat, o Botsify, o Chatfuel que promete a criação de um chatbot em apenas 7 minutos, o Blip, o Bothub.it, entre várias outras. Essas plataformas auxiliam na criação dos chatbots que podem ser publicados em sistemas de mensagens como o Facebook Messenger, o Skype, o Microsoft Teams, o Viber, entre outros.

Com o passar do tempo, várias técnicas foram escolhidas e utilizadas pelos desenvolvedores para a confecção dos agentes de conversação, segundo Masche and Le (2018) e

aza et al. (2018), as técnicas comumente utilizadas atualmente são: a correspondência de padrões, cleverscript, chatscript, AIML (*Artificial Intelligence Markup Language*), técnicas de parsing, SQL e banco de dados relacional, cadeia de Markov, truques de linguagem e as técnicas de processamento textual já citadas previamente (NLU, NLP, NLG, por exemplo).

Outras tecnologias que utilizam de técnicas de inteligência artificial como deep learning também são amplamente usadas em vários contextos como na análise de sentimento ou geração de conteúdo para complementar a base de dados. Uma tecnologia bastante utilizada nestas áreas é o Google Cloud NLP API (Google, 2018), que contém um módulo para análise de sentimento.

À exemplo do chatbot desenvolvido por Bird et al. (2019) e do MILABOT (Serban et al., 2017), também há a possibilidade de construção de sistemas de conversação áptos a aprender através da própria iteração com os usuários. Esses tipos de sistema utilizam técnicas de LSTM (Long Short-Term Memory), ou seja, múltiplas redes neurais recorrentes para predizer uma saída baseada na entrada e no estado atual da rede, mensagens desconhecidas são armazenadas e também são utilizadas como entrada na rede.

De maneira geral, segundo Lokman and Ameen (2019), o design dos chatbots modernos podem ser categorizados de acordo com seu domínio de conhecimento (se é um domínio aberto ou fechado), pela maneira que é realizada a geração da resposta (recuperação ou generativa), de acordo com a maneira em que o texto é processada (por exemplo, incorporação de vetor) e se utiliza modelos de machine learning.

2.2.3 Categorização dos chatbots

Existem várias maneiras de classificação para os agentes de diálogos, Jurafsky and Martin (2019) coloca os sistemas de conversação de domínio aberto em três principais categorias: os sistemas baseado em regras, os sistemas de recuperação de informação e os modelos codificador-decodificador, enquanto que põe os agentes de conversação orientados à tarefas em apenas uma categoria, os de arquitetura baseada em quadros ou cenários (arquitetura GUS).

O chatbot ELIZA foi o pioneiro na classe de agentes de conversação que utilizam do sistema baseado em regras. Como citado brevemente na seção de história e evolução dos chatbots, ELIZA busca nas sentenças usadas pelos seus usuários um padrão dentre vários mapeados dentro do seu banco, para assim gerar uma resposta. Para esses chatbots, cada regra é ligada a uma palavra chave que pode aparecer nas sentenças dos usuários. Na figura 2.2, pode-se ver o exemplo de como o chatbot ELIZA buscava aplicar a regra apropriada de acordo com as palavras chave encontradas. Nesse tipo de arquitetura cada palavra chave possui uma classificação, sendo as palavras mais específicas uma classificação maior que as palavras mais gerais.

```
function ELIZA GENERATOR(user sentence) returns response

Find the word w in sentence that has the highest keyword rank
if w exists
    Choose the highest ranked rule r for w that matches sentence
    response  $\leftarrow$  Apply the transform in r to sentence
    if w = 'my'
        future  $\leftarrow$  Apply a transformation from the 'memory' rule list to sentence
        Push future onto memory stack
    else (no keyword applies)
        either
            response  $\leftarrow$  Apply the transform for the NONE keyword to sentence
        or
            response  $\leftarrow$  Pop the top response from the memory stack
return(response)
```

Figura 2.2: Esboço simplificado do algoritmo utilizado pelo chatbot ELIZA

Fonte: (Jurafsky and Martin, 2019)

De maneira semelhante do chatbot baseado em regra, os sistemas de recuperação de informação se preocupam em gerar apenas uma resposta por vez, para a sentença (ou as sentenças), previamente postada pelo usuário. Segundo Jurafsky and Martin (2019) o princípio por trás dessa categoria de agentes de conversação, é responder a uma sentença, repetindo uma frase previamente armazenada em uma coleção de escritos de textos humanos (de conversas humano-humano), ou seja, dada uma frase e um corpus (coleção de documentos ou textos sobre determinado tema), o sistema baseado em recuperação de informação utiliza um algoritmo para escolher uma resposta apropriada a partir do corpus.

Esse algoritmo normalmente segue dois métodos, retornando a resposta de acordo com a rodada mais similar da conversa, ou retornando diretamente a rodada mais similar, e pode ser construído usando técnicas de aprendizado de máquina. Uma rodada aqui é descrita como uma troca de mensagens entre um usuário *x* e outro *y* armazenada dentro do corpus. O chatbot pioneiro nessa categoria foi o COBOT (Isbell et al., 2000), que utilizava como corpus uma combinação entre o manifesto de Unabomber, artigos sobre abdução alienígena e roteiros de “O grande Lebowski” e “Planeta dos macacos”.

O modelo codificador-decodificador, de maneira simplificada, nada mais é do que uma versão, utilizando aprendizagem de máquina, dos sistemas baseados em regras. Nesse tipo de modelo, o sistema aprende como gerar uma resposta para uma pergunta ou sentença feita pelo usuário, a partir de modelos de inteligência artificial com base em um corpus. Esses sistemas podem utilizar diversos algoritmos de *machine learning*, de aprendizagem por reforço ou ainda técnicas de NLP, NLU, entre outras, para garantir conversas mais

naturais e a continuidade das mesmas.

Tanto o modelo codificador-decodificador quanto o de recuperação de informação são ditos sistemas baseados em corpus e demandam grande quantidade de informação, ou seja, grandes datasets de conversas reais entre humanos são necessários.

A arquitetura baseada em cenários, utilizada nos diálogos orientados a tarefas (como ajudar os usuários a comprar algum produto ou reservar uma mesa em um restaurante), e como o próprio nome sugere, trabalha em cima de *frames*, uma estrutura de conhecimento que representa os tipos de intenções que o sistema pode extrair a partir das sentenças dos seus usuários. Essa estrutura de conhecimento consiste em uma coleção de *slots*, no qual, cada um pode ter um conjunto de valores possíveis (Jurafsky and Martin, 2019). O conjunto dos *frames* é chamado de ontologia de domínio.

Chatbots baseados em cenários são vinculados por um conjunto de informações pré-definido. Mas mesmo assim, fornecem aos usuários um grau mais alto de liberdade quando comparados com os chatbots baseados em regras (Galitsky, 2019). Um exemplo dessa liberdade maior é o fato que nesse tipo de arquitetura as questões que o sistema faz podem ser feitas em qualquer ordem. Vários sistemas modernos utilizam desta arquitetura, como é o caso da Siri da Apple, da Alexa da Amazon e do Google Assistant.

2.3 Chatbots e e-services

Com o passar do tempo, é notório perceber que os clientes de lojas de todos os tipos estão passando a utilizar cada vez mais os meios de comunicação *online* quando possível, ou seja, disponíveis na internet. Seja por vontade própria, por comodidade ou por situações adversas, o atendimento via *chat* e de forma *online* se tornou não apenas um diferencial, mas essencial para o funcionamento das lojas de grande e pequeno porte, e com isso, essas lojas tem passado a adotar ainda mais esse tipo de serviço, que antes apenas lojas de grandes marcas ofertavam.

Esse tipo de comunicação virtual visa principalmente manter o cliente satisfeito, melhorar o relacionamento entre ele e a marca (ou loja), prover informações úteis e engajá-lo de forma que ele possa obter uma boa experiência, aumentando assim, as chances de conversão. Para alcançar esses objetivos, um dos principais requisitos necessários é a disponibilidade do agente de comunicação para responder de forma instantânea as requisições dos usuários, o que ressalta a importância dos chatbots para este tipo de tarefa.

Chung et al. (2018) mostra em seu artigo “*Chatbot e-service and customer satisfaction regarding luxury brands*”, a importância dos agentes de comunicação na construção de um bom relacionamento com o cliente, na sua experiência com a marca e no processo de venda. Porém como já dito anteriormente, a construção de um chatbot demanda a necessidade de uma base de dados, e no caso deste trabalho, uma base de dados com conversas entre

lojistas e clientes e ainda com dados de moda, a cerca das peças de roupa à venda.

Big data tem ganhado uma importância significativa no mundo da moda, principalmente na última década (Jain et al., 2017), onde esses dados tem sido utilizados na construção de sistemas que ajudem os a industria da moda a entender a demanda e as preferências dos seus usuários, bem como tem sido utilizados na confecção de agentes que interajam com esses clientes.

2.4 Introdução a Big Data

Outro conceito bastante importante é o conceito de *big data*, um termo utilizado no mundo da tecnologia para se referir a um grande volume de dados - estruturados ou não-estruturados - que pode ser gerado por exemplo, cotidianamente nas grandes empresas (De Mauro et al., 2014). Esse conceito se refere a uma quantidade dados tão grande, que é gerada tão rápida ou que é tão complexa, que é muito difícil de se processar utilizando metodologias tradicionais.

A definição de *big data* é famosa por ser composta por 3 V's: Volume, Velocidade e Variedade como ilustrado na imagem 2.3, sendo que alguns autores ainda adicionam mais dois V's, a veracidade e o valor (De Mauro et al., 2014). Volume trata da capacidade de armazenamento das plataformas e da quantidade dos dados nas mesmas, desse conceito surge os data lakes, que armazenam uma grande quantidade de dados não estruturados. Velocidade que representa a taxa mais rápida na qual os dados são recebidos e administrados. E o conceito de variedade que trata dos vários tipos de dados disponíveis, como por exemplo, vídeos, imagens, textos, entre outros.




Figura 2.3: Os três V's do *Big Data*

Fonte: (Sagiroglu and Sinanc, 2013)

Ferramentas que lidam e armazenam essa grande quantidade de dados são de grande importância em diversas atividades de negócios, já que esses dados são comumente utilizados na definição de estratégias de marketing e em estratégias para direcionamento de esforços, gerando assim um aumento na produtividade, uma redução de custos e ajudando em uma tomada de decisão mais inteligente. Além disso podem ser utilizados também na customização da experiência do cliente, na área da segurança e detecção de fraude, no desenvolvimento dos produtos e até mesmo no impulsionamento da inovação dentro da empresa.

Bons exemplos de empresas que usam *big data* são a Amazon que utiliza principalmente para as sugestões de compras e produtos que possam interessar aos seus clientes, a Netflix na recomendação de filmes e séries de acordo com o perfil do usuário e o Spotify que utiliza também na recomendação de músicas, playlists, artistas e álbuns aos seus usuários. Além disso, as maiores e mais conhecidas empresas que fornecem serviço para armazenamento de dados e análise na nuvem são a Google, a Amazon e a Azure.

2.5 Coleta de dados e formação de corpora

Independentemente do tipo de agente de conversação que esteja sendo criado ou do design e metodologia utilizado, um ponto em comum a todos, é a formação de uma base de dados ou base de conhecimento. Segundo Kuligowska (2015), a base de conhecimento constitui a essência da existência dos chatbots, ela armazena todos os dados, informações e conhecimento a cerca da realidade para ser utilizada pelo agente de conversação em suas iterações com os usuários. Serban et al. (2018) diz que para alcançar bons resultados, os chatbots modernos às vezes precisam de centenas de milhões e até mesmo bilhões de palavras em seus corpus.

Para a obtenção de dados e formação de uma base de conhecimento com o objetivo de treinamento dos modelos utilizados nos chatbots, muitas técnicas diferentes podem ser utilizadas, como entrevistas ou simulações de situações reais do contexto em que o chatbot será utilizado, onde o autor pode utilizar modelos estruturados (perguntas previamente estabelecidas), não estruturados (conversas livres) ou semi-estruturados (conversas livres, porém com um guia). Devido a Internet e a facilidade de uso da mesma, também pode ser feito uma coleta de dados em mídias sociais através de web crawlers, API's abertas, ou outras ferramentas para mineração de dados.

Xu et al. (2017) em seu artigo “*A new Chatbot for Customer Service on Social media*” cita como primeira etapa na construção de seu sistema, a coleta e limpeza dos dados. Para a coleta de dados, o mesmo utilizou a API de dados abertos do Twitter, onde usou cerca de 1 milhão de conversas entre usuários e agentes de mais de 60 marcas. De maneira semelhante, Jeong and Seo (2019) utiliza o Twitter como fonte de dados para sua base de

conhecimento para um sistema de perguntas e respostas (Q&A system).

No artigo “*Modelling Domain Relationships for Transfer Learning on Retrieval-based Question Answering Systems in E-commerce*”, Yu et al. (2017) informa que utilizou como base de dados em seus experimentos, um dataset de pares de perguntas e resposta retirados do Quora e disponível na plataforma Kaggle, e uma própria base de conhecimento retirada do sistema do AliExpress com cerca de 15.000 pares das perguntas e respostas mais frequentes do sistema.

Também é possível utilizar bases de conhecimento já montadas com os diálogos entre humanos ou até mesmo, diálogos entre humanos e sistemas de conversação. Serban et al. (2018) em seu artigo “*A Survey of Available Corpora for Building Data-Driven Dialogue Systems*” mapeia vários datasets disponíveis para construção de chatbots, incluindo datasets de conversas escritas e de conversas faladas. Para complementação das bases de dados, também é possível utilizar ferramentas de geração de texto.

Um marco para a geração de texto foi a criação do modelo *GTP-2* (Radford et al., 2019), treinado simplesmente para prever a próxima palavra com base nas anteriores e em 40GB de texto coletado na Internet, um exemplo de uso pode ser visto no site Tal (2019). Outras ferramentas como é o caso do NLP Augmentation (Ma, 2019) e do Chatito (Pimentel, 2018), foram criadas com a finalidade de ajudar os desenvolvedores no aumento de suas bases para treinamento através de técnicas de data augmentation.

Mesmo com tantas bases de dados e metodologias de construção de datasets disponíveis, garantir a qualidade desses dados através de uma limpeza dos dados ou através de boas fontes é imprescindível para evitar casos como o Tay (Microsoft, 2016), um chatbot que funcionava no Twitter e era capaz de aprender através de iterações anteriores com os usuários, onde devido ao uso por pessoas com más intenções, após 16 horas online, o mesmo começou a postar tweets extremamente ofensivos e racistas. Bird et al. (2019) utiliza de um filtro para evitar que o mesmo aconteça com seu sistema de conversação.

2.6 Privacidade e anonimização dos dados

Dados anonimizados, de acordo com a Lei Geral de Proteção de Dados Pessoais (LGPD), são os dados que originalmente pertenciam ou faziam referência a uma pessoa, mas que passaram por etapas que garantiram a desvinculação desses dados a essa pessoa (SERPRO, 2022). Em outras palavras, o dado anonimizado não permite que através de nenhum meio se descubra o titular do dado. Caso seja possível a identificação da pessoa titular dos dados, o dado não está de fato anonimizado e está sujeito a LGPD.

A LGPD, lei nº 13.709/2018, é uma lei que regula o tratamento de dados pessoais no meio digital ou físico e assim protege os direitos fundamentais de liberdade e de privacidade de cada indivíduo (Brasil, 2018). São exemplos de dados pessoais: nome, sobrenome, data

e local de nascimento, documentos como o RG, CPF, número de telefone, endereço de e-mail, endereço residencial, etc.

2.7 Intenções e entidades

Em um diálogo, ambos os agentes participantes estão sempre expressando intenções através de suas palavras e sentenças. Ao dizer “obrigado” por exemplo, pode se dizer que a intenção expressada pelo falante é a de gratidão, satisfação ou algo semelhante, ao dizer “adeus” a intenção expressada pode ser identificada como a finalização de uma conversa e assim por diante. A intenção, por assim dizer, nada mais é do que o sentido daquela palavra ou frase naquele contexto, o real significado que realmente o agente quis expressar.

Em chatbots relacionados a venda ou assistência ao usuário por exemplo, podemos dizer que a intenção se refere ao objetivo que o cliente tem em mente ao digitar uma dúvida ou um comentário. Logo, a intenção se torna um fator crucial e extremamente importante na construção e desenvolvimento de um agente de conversação. A habilidade de um chatbot de identificar a intenção do usuário que o está usando é diretamente relacionada ao sucesso da interação entre ambos, ou seja, a realização de uma venda, a clarificação de uma dúvida e etc.

Para que um chatbot seja bom na identificação de intenções, ele deve ser treinado com um modelo eficiente, ou seja, que tenha uma boa acurácia em diferentes cenários, com acesso a uma grande quantidade de dados de treinamento de qualidade, além disso, o chatbot também pode tomar vantagem de *machine learning* para que esteja sempre evoluindo e melhorando conforme a entrada dos usuários e o surgimento de novos dados pertinentes ao contexto em que o chatbot está inserido.

Embora estejam ambos presentes em uma frase e sejam ambos considerados o alicerce do entendimento da linguagem natural por contexto, é importante ressaltar a diferença entre a intenção e a entidade para um chatbot. De forma objetiva pode-se dizer que a intenção é o objetivo que o usuário tem em mente no momento em que ele questiona ou comenta sobre algo, ou seja, é o real motivo por trás de cada mensagem que o chatbot recebe, o que ele está procurando, pode-se dizer ainda que a intenção é tudo aquilo que o usuário quer para que o faça sair da interação satisfeito, já as entidades referem-se aos elementos, dados, texto, ou seja, aos modificadores que o cliente utiliza para descrever suas exigências.

Estes dois elementos se complementam para fornecer informações a respeito das demandas do usuário, por exemplo, o cliente utilizando um website de varejo que vende roupas digita: “Vocês possuem blusas brancas?”, para esse caso, o bot identificaria a intenção do usuário, que seria comprar uma peça de roupa, e identificaria a entidade ao qual ele se refere que seria a blusa branca e assim disponibilizaria um catálogo de blusas

brancas disponíveis em estoque.

Um outro exemplo em um diferente contexto seria a de um usuário que pergunta como estará o tempo na cidade Maceió na próxima terça-feira. A intenção do usuário aqui é saber sobre o tempo em determinada cidade em determinado dia, enquanto a cidade “Maceió”, o dia “Terça” são entidades que especificam a informação que o usuário está procurando. A intenção e a entidade são ambas essenciais para que os chatbots consigam entregar o que o cliente deseja de forma satisfatória.

A diferença e a importância entre as entidades e as intenções fica mais evidente ainda, quando o usuário não especifica claramente o que ele deseja. Utilizando como exemplo um usuário que, como no exemplo anterior, está procurando por roupas em um *website* de venda de roupas mas que dessa vez deseja comprar calças jeans especificamente, o mesmo digita algo como: “Vocês possuem calças jens?”. Neste exemplo a intenção do cliente é a de adquirir calças jeans, mesmo que não tenha sido específico ou tenha digitado algo com erros ortográficos, o chatbot deve ser capaz de identificar a real intenção do usuário para fornecer um retorno satisfatório.

Pode-se dizer que quanto mais entidades e intenções um chatbot é capaz de identificar, mais robusto ele é. Para um melhor entendimento do que está acontecendo em uma conversa é preciso identificar as intenções que estão por trás de cada sentença dita pelo usuário. O processamento de linguagem natural é o responsável por ajudar nessa tarefa, extraindo informações relevantes processando-as e fornecendo o retorno que o usuário precisa. O mesmo é considerado a fundação no qual chatbots inteligentes são construídos.

Quando diz-se que um chatbot é baseado em intenções, significa que o mesmo é um chatbot que trabalha detectando as intenções dos usuários, então ao invés de confiar ou ser literal em relação as entradas do cliente, ele pode identificar o verdadeiro significado que a mensagem está tentando passar para que possa oferecer uma resposta devidamente relevante.

Este tipo de chatbot oferece múltiplos benefícios relacionados a experiência do usuário na plataforma, incluindo: uma maior naturalidade das conversas, o usuário pode conversar de um jeito similar a uma conversa com uma pessoa real, não sendo preciso prover termos muito específicos para que o sistema entenda qual seu objetivo, fazendo com que a conversa seja mais fluída, suave e engajadora.

Além disso, como já falado anteriormente, as conversas se tornam mais flexíveis, além de serem menos restritas quando comparadas por exemplo aos chatbots baseados em fluxos. Eles são mais adaptáveis as mudanças do usuário, logo, eles conseguem responder bem as mudanças de tópicos e contexto, fornecendo serviços mais customizáveis de acordo com as demandas do cliente.

Em resumo esse tipo de chatbot analisa caso por caso, ou seja, cada interação se desenrola de forma diferente da anterior, e por isso IA, aprendizagem de máquina e PLN são tão importantes para esse tipo de chatbot. Mais especificamente, esse tipo de agente

de conversação olha termo por termo procurando palavras chaves e entidades para assim identificar intenções e fornecer uma resposta precisa e sob medida para cada usuário. A figura 2.4 demonstra a diferença entre intenções e entidades para diversas frases de exemplo.

Entradas		Intenções e Entidades
 GABRIEL 12 ABRIL 2022	Gostaria de comprar uma passagem de avião para Nova York.	Intenções: Comprar passagem Entidades: Avião; Nova York
 EVANDRO 21 MAIO 2022	Você poderia reservar um restaurante de frutos do mar?	Intenções: Reserva de restaurante Entidades: Restaurante; Frutos do Mar
 LUCAS 05 JUNHO 2022	Vocês possuem roupas de banho?	Intenções: Dúvida sobre estoque Entidades: Roupas de banho
 THALES 12 JUNHO 2022	Reserve um restaurante próximo a mim para hoje a noite.	Intenções: Reserva de restaurante Entidades: Hoje à noite; próximo a mim

Figura 2.4: Infográfico demonstrando a diferença entre intenções e entidades para um chatbot

Fonte: Do próprio autor

2.7.1 Tipos de intenções

De acordo com a definição de intenções apresentada anteriormente é possível notar a vasta gama de intenções presentes em um diálogo entre dois agentes. Cada conjunto de

sentenças ou mesmo cada sentença em específico pode representar um diferente objetivo por parte do usuário que utiliza o sistema.

Essas intenções podem ser de diferentes tipos como por exemplo: pesquisa genérica, questões e respostas, recomendações e assim por diante, variando de acordo com o contexto em que o sistema de conversação está inserido, o padrão utilizado para desenvolvimento do chatbot, entre outros fatores.

Em seu artigo “*Chatbot Integration in Few Patterns*”, [Baez \(2020\)](#) pôde identificar mais de dez tipos de padrões de intenção comumente utilizados pelos diferentes tipos de chatbot. Importante ressaltar que de acordo com o objetivo do sistema de conversação o mesmo poderá identificar diferentes tipos de intenções.

2.7.2 Classificação de intenções

Em um sistema de diálogo, o classificador de intenções é o módulo responsável por identificar e classificar as intenções de cada enunciado inserido pelo usuário de forma automatizada. Simplificadamente, um classificador de intenções automaticamente analisa e categoriza o texto inserido em intenções de forma a automatizar processos e gerar conhecimento de valor.

O classificador de intenções faz parte do módulo de NLU. A figura 2.5 mostra uma arquitetura simplificada de um chatbot onde é possível ver o módulo de compreensão da linguagem natural recebendo dados através da interface com o usuário, processando esses dados e enviando os resultados para o módulo de gerenciamento de diálogo que faz a ponte entre a entrada do usuário e o backend da aplicação que contém todo tipo de informação relevante, como banco de dados e lógica necessária para processar a requisição do usuário.




Figura 2.5: Arquitetura simplificada de um chatbot

Fonte: Do próprio autor

Na imagem 2.6, no qual o autor implementa um chatbot utilizando a ferramenta Rasa ([Bocklich et al., 2017](#)), ilustra um esquema que demonstra o fluxo usual do módulo

de NLU em um sistema de diálogo. Nele pode-se notar onde está localizado o módulo responsável pela classificação de intenções.




Figura 2.6: Esquema da classificação de intenções e da extração de entidades utilizando o processamento de linguagem natural do software Rasa

Fonte: (Nguyen, 2021)

Um classificador de intenções comumente utiliza de técnicas de aprendizagem de máquina, processamento de linguagem natural e inteligência artificial de forma geral para automaticamente associar palavras, expressões e contextos com uma intenção particular. Por exemplo, um classificador de intenções pode associar que a palavra obter, ou a palavra adquirir está associado a uma intenção de compra.

Vale evidenciar que para que um classificador de intenções obtenha bons resultados é importante que se tenha uma boa base de dados, ou seja, com uma quantidade considerável de dados e devidamente anotada de acordo com o contexto em que o classificador de intenções vai atuar. É possível encontrar diversas bases de dados públicas disponíveis na internet para diferentes cenários, o Cornell Movie-Diologs Corpus (Danescu-Niculescu-Mizil and Lee, 2011) por exemplo é um conjunto de dados que contém uma grande coleção rica em metadados de conversas fictícias extraídas de roteiros de filmes.

Através da classificação de intenções, as empresas e seus serviços prestados se tornam mais personalizáveis e mais centrados no cliente, faz com que as respostas aos desejos do consumidor sejam mais precisas e rápidas, aumentando a satisfação desses consumidores de modo geral. Logo, nota-se a importância dos classificadores de intenção para as empresas e porque o mesmo é amplamente utilizado no mercado moderno.

2.8 Introdução ao aprendizado de máquina

Aprendizado de máquina (ou *machine learning* em inglês) é uma vertente da inteligência artificial dedicado a melhorar algoritmos de computação sem programação explícita, automatizando assim a construção de modelos analíticos. Ele surge da premissa em que sistemas aprendem com dados e assim podem identificar padrões e tomar decisões com o mínimo ou até mesmo completamente sem a intervenção humana.

De acordo com [Chinnamgari \(2019\)](#) o aprendizado de máquina pode ser subdividido em 5 grupos: aprendizado supervisionado, aprendizado não-supervisionado, aprendizado semi-supervisionado, aprendizado por reforço e transferência de aprendizado.

No aprendizado supervisionado, os algoritmos são treinados por meio de entradas rotuladas onde há exemplos a respectiva saída desejada, ou seja, são treinados com uma entrada na qual a saída desejada é previamente conhecida, dessa forma o algoritmo consegue aprender regras que mapeiam entradas e saídas. Alguns exemplos conhecidos e consolidados de algoritmos supervisionados são: o SVM (*Support Vector Machine*), árvore de decisão, k-vizinhos mais próximos entre outros.

Os algoritmos de aprendizado não-supervisionado ao contrário dos algoritmos supervisionados são treinados com entradas em que a saída esperada não é informada, logo, o algoritmo deve descobrir por si só os padrões ocultos nos dados. Alguns exemplos de algoritmos que adotam essa abordagem são: *k-means clustering*, *hierarchical clustering*, *fuzzy clustering* e etc.

Quando se fala de algoritmos de aprendizado semi-supervisionado se fala de algoritmos que utilizam de um híbrido entre as duas abordagens anteriormente citadas. É disposto um conjunto de dados mesclados, rotulados e não-rotulados, para o treinamento. As GANs - *Generative Adversarial Networks* ([Goodfellow et al., 2014](#)), são um exemplo bastante utilizado de algoritmo de aprendizado semi-supervisionado.

O aprendizado por reforço (do inglês, *reinforcement learning*) é um método de machine learning em que o algoritmo descobre através de "tentativa e erro" quais ações geram maiores "recompensas". Aqui o algoritmo também não recebe dados já rotulados para aprendizagem mas uma definição de recompensa que o guia nas decisões a serem tomadas, fazendo com que o mesmo chegue a solução mais otimizada por meio de tentativa e erro. Um algoritmo de aprendizagem por reforço bastante popular é o Q-learning.

Já o método de transferência de aprendizado, trata-se da reusabilidade de modelos já construídos para a resolução de problemas relacionados. Por exemplo, um modelo construído para reconhecer certos tipos de automóveis como caminhões, já gerou um certo conhecimento que poderia ser aproveitado em outras tarefas como no reconhecimento de carros. Alguns exemplos de modelos pré-treinados disponíveis publicamente são o MobileNet e o Word2Vec.

2.8.1 Redes neurais e aprendizagem profunda

Aprendizagem profunda ou *Deep learning* é uma categoria dos algoritmos de aprendizagem de máquina que fazem usos de redes neurais artificiais para a resolução de problemas. Essas redes neurais artificiais são inspiradas nos neurônios humanos e fazem uso da teoria dos grafos para organizar os algoritmos em múltiplas camadas (sendo algumas ocultas) que contém arestas e vértices.

Os algoritmos de aprendizagem profunda podem utilizar diversas arquiteturas como é o caso das redes neurais sem realimentação, as redes neurais convolucionais (CNN, *Convolutional Neural Networks*, as redes neurais recorrentes (RNN, *Recurrent Neural Networks*) como é o caso da LSTM e da BiLSTM utilizadas nesse trabalho, os transformers como é o caso do Bert também utilizado por esse trabalho, entre outras.

3

Metodologia

Para o desenvolvimento das atividades a fim de alcançar os objetivos propostos com êxito, várias tarefas foram executadas, partindo desde a pesquisa e fundamentação teórica em artigos, livros e outros materiais pertinentes e relacionados à temática do projeto, até o uso dos conhecimentos obtidos para o desenvolvimento de *aplicações* e *scripts* para diversas atividades como coleta de dados, treinamento e avaliação de modelos.

De modo geral, para o desenvolvimento desse trabalho, foram realizadas duas etapas: a teórica e a prática, sendo a primeira explicitada no capítulo 2, que consistiu de um processo de pesquisa, análise e estudo a cerca das ferramentas e maneiras utilizadas tanto pela indústria quanto pela academia diante do tema aqui apresentado, utilizando principalmente de referências bibliográficas atuais e relevantes, com o principal objetivo de ampliar o conhecimento sobre a área em questão e realizar uma validação teórica da ideia.

Já a segunda etapa consistiu na aplicação de conhecimentos técnicos de programação para o desenvolvimento de ferramentas que pudessem auxiliar na conclusão dos objetivos propostos, e que assim pudessem ajudar na realização de uma validação prática da ideia proposta. Vale lembrar que essas duas atividades, muitas vezes se misturam ou se repetem de forma cíclica, ou seja, tanto a parte prática quanto a parte teórica são realizadas repetidamente e de forma constante afim de se obter um aperfeiçoamento em ambas as etapas.

Vale salientar que a etapa prática também pode ser dividida em duas outras partes: o estudo comparativo entre técnicas de aprendizado de máquina para classificação de intenções e a coleta de dados e formatação de uma base dados em português com diálogos no contexto do e-commerce de roupa. A seguir, de forma mais detalhada, constam as etapas realizadas com o propósito de se alcançar e cumprir os objetivos aqui propostos.

3.1 Estudo teórico

Tendo como objetivo adquirir e ampliar o conhecimento acerca da temática proposta, o estudo teórico se deu a partir de uma pesquisa bibliográfica de artigos científicos, revistas, livros, e outras fontes da literatura, obtendo assim, referências confiáveis e de qualidade.

Nesta etapa foram estudados conceitos e teorias a cerca de assuntos essenciais e relacionados com o tema, como as tecnologias e métodos para construção e desenvolvimento de todas as etapas dos sistemas de conversação, assim como sua evolução ao longo do tempo, foram estudados também, conceitos como o de Big Data, NLP, NLU e coleta de dados, além da atuação dos chatbots no e-commerce.

No auxílio a parte prática, foram estudados a linguagem de programação python, bem como o framework Django e noções de desenvolvimento web em geral, além de conteúdos acerca de bancos de dados relacionais, tokenização, inteligência artificial, aprendizagem de máquina, entre outros conceitos necessários para o correto desenvolvimento do projeto.

3.2 Estudo comparativo entre técnicas de aprendizado de máquina para classificação de intenções

Esta etapa destinou-se ao estudo comparativo entre bases de dados, modelos e técnicas de aprendizado de máquina afim de se realizar o desenvolvimento de um classificador de intenções inserido no contexto de e-commerce de roupa. Para tanto, seguimos duas etapas principais: a pesquisa bibliográfica e o estudo comparativo em si, ambos detalhados nos subtópicos a seguir.

3.2.1 Pesquisa bibliográfica

A pesquisa bibliográfica também pode ser dividida em duas partes, a primeira focou em realizar um levantamento das bases de dados disponíveis publicamente para desenvolvimento de classificadores de intenções, mais especificamente, uma base de dados que contenha diálogos no contexto do e-commerce de roupa.

Para escolha das bases de dados em si, utilizaram-se os seguintes critérios: o contexto, a quantidade de palavras, entidades e sentenças contempladas e a granularidade da classificação. Como já falado anteriormente, a base de dados deve estar inserida no mesmo contexto do classificador de intenções a ser criado, portanto e-commerce de roupa, com diálogos entre vendedores e clientes. Também é importante que haja um bom número de palavras e sentenças e que haja uma boa quantidade de classes e de diálogos por classe.

Através desta pesquisa fora escolhida a base de dados utilizada para treinamento e validação do classificador de intenções desenvolvido posteriormente por meio desse trabalho.

Já a segunda parte focou em realizar o levantamento acerca de quais modelos são mais utilizados para treinamento destes classificadores e a partir daí realizar a escolha dos modelos de aprendizado de máquina a serem avaliados. Esses modelos de aprendizagem de máquina foram avaliados e comparados entre si a fim de se escolher qual seria utilizado no produto final. A metodologia utilizada assim como os resultados obtidos serão descritos nas próximas seções.

3.2.2 Estudo comparativo

Para o estudo comparativo entre as técnicas e modelos de aprendizado de máquina para a construção do classificador de intenções a principal métrica escolhida a ser avaliada foi a acurácia obtida após treinamento dos modelos analisados, seguido pela análise da matriz de confusão.

O estudo foi realizado seguindo as seguintes etapas: a coleta e o pré-processamento dos dados nas bases de dados escolhidas na etapa anterior de pesquisa bibliográfica, o treinamento dos modelos de aprendizagem de máquina também obtidos através da etapa anterior, bem como a avaliação e o aprimoramento dos parâmetros do modelo.

Com relação a etapa do pré-processamento dos dados, em todas as bases de dados escolhidas foram analisadas e agrupadas as classes que eram comuns ou parecidas, também foram removidas classes que tinham pouquíssimos dados, o parâmetro escolhido foram classes com menos de 10 sentenças. As classes também receberam pesos diferentes de acordo com a quantidade de sentenças presente em cada uma.

Os modelos testados receberam diferentes tipos de tratamento, um deles foi a remoção das chamadas *stop words*. Essa lista de palavras normalmente contém determinantes, preposições e até mesmo alguns adjetivos, são palavras comumente utilizadas e que acabam agregando menos valor as sentenças, logo, removendo-as, o modelo pode focar no que realmente importa, ou seja, nas palavras que tem mais valor.

Para esse projeto, utilizou-se uma lista de stop words em inglês disponível na biblioteca NLTK (Loper and Bird, 2002), uma plataforma gratuita e de código aberto desenvolvida em Python com ferramentas voltadas para o processamento de linguagem natural. São exemplos comuns de stop words: um, uma, o, como, através, bom e assim por diante.

Ainda na parte de limpeza de dados também foram retirados os símbolos de pontuação tais como: “)”, “(”, “#”, “,”, “.”, “;”, entre outros. Como na remoção dos *stop words*, isso se faz necessário em alguns casos para que no treinamento se foque no que há de mais importante, no conteúdo que traz mais significado.

Importante ressaltar que os modelos foram testados utilizando e não utilizando as etapas anteriormente descritas, a remoção de *stop words* e a remoção de símbolos. Isto foi feito tendo em vista que para alguns casos essas etapas podem acabar prejudicando o entendimento e a aprendizagem do modelo. Os resultados detalhados destes experimentos

podem ser vistos na seção 4.1.

Continuando a fase de pré-processamento dos dados, para os modelos SVC, LSTM e BiLSTM, os dados foram submetidos a um processo chamado de lematização. Na lematização procura-se reduzir a palavra à sua raiz, a sua forma base, agrupando assim diferentes formas da mesma palavra, para isso, retira-se todas as inflexões chegando ao lema da mesma. Para realizar esse processo fez-se uso mais vez da biblioteca NLTK.

Outro procedimento adotado foi a tokenização seguida pela vetorização das sentenças. De forma resumida, a diferença entre a vetorização e a tokenização é que a primeira trata-se do processo de conversão de um texto em uma representação numérica, já a segunda é o processo de particionar um texto em tokens, já os tokens podem ser definidos como partículas (letras, palavras ou subpalavras), que contém significado em si mesmas.

Para isto, dois algoritmos foram utilizados: o *One-Hot-Encoding* e o *TF-IDF*. O One-Hot-Encoding de maneira simplificada, gera um vetor com o tamanho igual ao número de categorias/classes e assim determina a presença de uma dada palavra. Cada categoria se transforma em uma coluna que é preenchida com o valor 1 caso o texto classificado pertença à categoria e 0 no caso contrário.

Especificamente para o modelo SVC foi realizado o processo de vetorização utilizando o algoritmo TF-IDF, abreviação do termo em inglês “Term Frequency Inverse Document Frequency”, disponível na biblioteca sklearn para python. Esse algoritmo é bastante utilizado para transformação de texto em uma representação significativa de números, utilizada para ajudar o algoritmo de aprendizagem de máquina na realização de previsões.

Ainda com relação ao modelo SVC, no experimento também foi acrescentada à fase de pré-processamento dos dados, a técnica chamada de “Word to Vector” (Mikolov et al., 2013), um método estatístico que como o próprio nome cita, transforma textos em vetores, mas que utiliza de técnicas de aprendizagem profunda para reconhecer palavras semelhantes e assim incorporá-las de maneira eficiente, vale lembrar que o *Word2Vec* parte de um modelo pré-processado com uma quantidade enorme de dados.

Ao final, foi observado como os modelos reagiram após serem treinados com todas as bases de dados selecionadas, e com isso o modelo e a base de dados que geraram melhores resultados foram escolhidos.

3.3 Coleta de dados e criação de um dataset

De forma paralela a revisão bibliográfica da literatura descrita na seção 3.1, com o objetivo primário de coletar dados para formação de um dataset no contexto de e-commerce com sentenças em português, foi-se realizado o projeto e implementação de um sistema de chat simples semi-estruturado com a função de simular uma situação real entre lojistas e clientes. Além disso, fora realizado uma parceria com uma loja online local para coleta

de conversas reais entre seus clientes e lojistas.

3.3.1 Chat para simulação de conversas entre lojistas e clientes

Essa solução foi construída utilizando no back-end a linguagem de programação python através do framework django e o banco de dados relacional postgresQL, além de tecnologias como o html, css, javascript e o framework materialize para o front-end. O chat foi hospedado na plataforma Heroku, também utilizou-se o Git e a plataforma GitHub para controle de versão, acompanhamento das atividades por parte dos orientadores e para a gestão dos arquivos.

O chat foi implementado optando por um modelo de conversação em que cada usuário tem sua vez de falar, também chamado de *turn-taking*, ou seja, quando o usuário da função cliente manda uma mensagem, ele permanece impossibilitado de enviar outra mensagem até que o usuário da função lojista responda, da mesma maneira acontece quando o usuário da função lojista envia uma mensagem, não podendo enviar outras mensagens até que o usuário cliente responda. Aqui também ficou decidido de que o lojista deveria sempre iniciar a conversa.

Esse tipo de modelo de conversação foi adotado por permitir um maior balanceamento entre as mensagens de ambas funções, em outras palavras, cada conversa irá possuir o mesmo número de mensagens entre os usuários lojista e cliente, e também por impedir que os usuários realizassem algum tipo de spam ou fugissem do tema apresentado que é de simular uma conversa real entre lojistas e clientes.

Após implementação do sistema responsável por armazenar e guiar as conversas simuladas, foram realizados dois experimentos com públicos distintos através da plataforma de simulação, sendo o primeiro realizado com 8 pessoas e o segundo com 14 pessoas, ou seja, no primeiro experimento houve 4 pessoas representando o cargo de lojista e 4 pessoas representando os clientes, já no segundo, houve 7 pessoas simulando a função de lojista e 7 pessoas simulando os clientes.

A partir da coleta dessas mensagens, foi realizada o mapeamento de todas as sentenças, iniciando com a limpeza dos dados, sendo removidas mensagens que representavam erros como por exemplo mensagens incompletas, além da remoção de nomes e outros dados vistos como sensíveis. Posteriormente a limpeza dos dados houve a atribuição da intenção que cada texto representa. Os resultados de ambos os experimentos são descritos no capítulo 4




Figura 3.1: Tela do sistema desenvolvido na perspectiva de um lojista mostrando o catálogo do estoque disponível

Fonte: Do próprio autor

A imagem 3.1 mostra a página principal da plataforma desenvolvida para a simulação de conversas entre lojistas e clientes na perspectiva de um lojista. A coleta dos dados gerados a partir dos experimentos foi realizada através de uma *API*, retornando as mensagens, os dados dos usuários que mandaram e receberam cada mensagem e também o momento (tempo) em que cada mensagem foi enviada.

3.3.2 Coleta de dados reais

Para validação dos dados gerados pela plataforma de chat de simulação de compra e venda de produtos e para ampliação do corpus gerado, foi realizada uma coleta de dados reais através de uma parceria com uma loja local que possui como principal fonte de faturamento a venda online através de canais de comunicação como o *Instagram* e o *Whatsapp*.

Para a coleta no *Whatsapp* foi desenvolvido um *Web Scraper* que conseguiu de forma automatizada coletar todas as conversas entre a loja parceira e seus clientes, já para o *Instagram*, algumas conversas foram cedidas pela lojista através de capturas de telas mas também foi utilizada uma extensão gratuita para o navegador *Chrome* de extração das conversas do *Direct* (plataforma de chat do *Instagram*) que forneceu todas as conversas no formato *JSON*. Dados sensíveis como nomes e números de celular foram ocultados por medida de segurança.

3.3.3 Categorização dos dados gerados e formação de corpora

Para a criação do corpora de conversas entre lojistas e clientes, todas as sentenças obtidas através dos experimentos com a plataforma de simulação e também as sentenças reais

coletadas pela parceria com a loja *My Trend* explicitada na seção anterior, foram mapeadas em categorias que pudessem representar o significado das mesmas.

Foram extraídas de todas as sentenças uma categoria geral que representasse a intenção que aquela mensagem estava passando, se era um cumprimento ou uma pergunta sobre algum produto e assim por diante. Essa extração se deu de forma manual pelo autor do trabalho aqui proposto e revisado por seus orientadores.

O formato escolhido para o mapeamento das conversas em categorias foi o formato *Json*. Este formato e essa metodologia de categorização, foram aderidos para que fosse facilitado o uso do mesmo no desenvolvimento de chatbots e também de uma ontologia. Esses dados se encontram disponíveis no apêndice A.



Resultados e Discussões

Nesta seção serão apresentados os resultados alcançados com o estudo comparativo afim de se realizar o desenvolvimento de um classificador de intenções para chatbots de e-commerce de roupa. Também serão explicitados os resultados obtidos acerca da formação de corpora, dos experimentos com a plataforma de chat para simulação de venda, além da coleta de dados relacionados as conversas reais entre lojista e cliente.

4.1 Estudo comparativo

4.1.1 Escolha dos modelos de aprendizado de máquina

Como já discutido anteriormente na seção 3.2.1, para a escolha dos modelos a serem aqui avaliados, foi-se feito uma revisão da literatura a respeito dos modelos mais utilizados no desenvolvimento de classificadores de intenções e como resultado os modelos escolhidos para serem avaliados foram: o LSTM ([Hochreiter and Schmidhuber, 1997](#)), o BiLSTM ([Graves and Schmidhuber, 2005](#)), o BERT ([Devlin et al., 2018](#)) e o SVC ([Cristianini and Shawe-Taylor, 2000](#)).

O LSTM (do inglês *Long Short Term Memory*), um tipo de rede neural recorrente (RNN) bastante utilizado em cenários que envolvem o processamento de linguagem natural devido as suas características especiais. De forma resumida, as RNNs se diferem de outros tipos de redes neurais por possuírem a característica de transferência de informações entre as tarefas executadas, ou seja, elas permitem que as informações persistam e sejam passadas de uma etapa da rede para a próxima.

As RNNs porém, possuem um problema em relação a transmissão de informações de "longo prazo", em outras palavras, quanto mais longe na rede está a informação que é preciso na etapa atual, mais as RNNs vão ter dificuldade em recuperá-la. E as LSTMs

são especificamente projetadas para evitar esse tipo de problema de dependência de longo prazo.




Figura 4.1: Arquitetura original da LSTM

Fonte: (Yu et al., 2019)

A figura 4.1, demonstra a arquitetura original da LSTM onde ao invés de possuir apenas uma única camada de rede neural como a RNN simples, o módulo de repetição possui várias camadas que interagem entre si, explicitamente projetado para evitar o problema de dependência de longo prazo.

O BiLSTM ou bidirectional LSTM é um modelo que consiste basicamente de duas LSTM conectadas o que permite o aumento efetivo da quantidade de informações disponíveis para a rede. A rede LSTM convencional é apenas capaz de fazer uso de informações disponíveis em contextos anteriores, em camadas anteriores, já a BiLSTM consegue ser treinada em ambas as direções de tempo simultaneamente, ou seja, ela consegue adquirir informações de camadas a frente e anteriores.

O modelo BERT (Bidirectional Encoder Representations from Transformers) para Processamento de Linguagem Natural, é um modelo de Deep Learning que faz uso de um mecanismo que aprende as relações contextuais entre palavras ou sub-palavras em um texto chamado de *Transformer*.

O codificador *Transformer* do BERT lê a sequência de palavras de um texto de uma vez, e por isso é considerado bidirecional, permitindo que o modelo aprenda o contexto de uma palavra com base no que está ao seu redor (direita ou esquerda da palavra).

SVC, em especial o Linear SVC (algoritmo utilizado nesse trabalho), é um modelo de aprendizado de máquina supervisionado que faz parte do conjunto de modelos de máquina de vetor de suporte, do inglês *Support Vector Machine* - SVM, que visa solucionar problemas de classificação através da geração de hiperplanos que fazem a separação dos grupos a serem classificados.

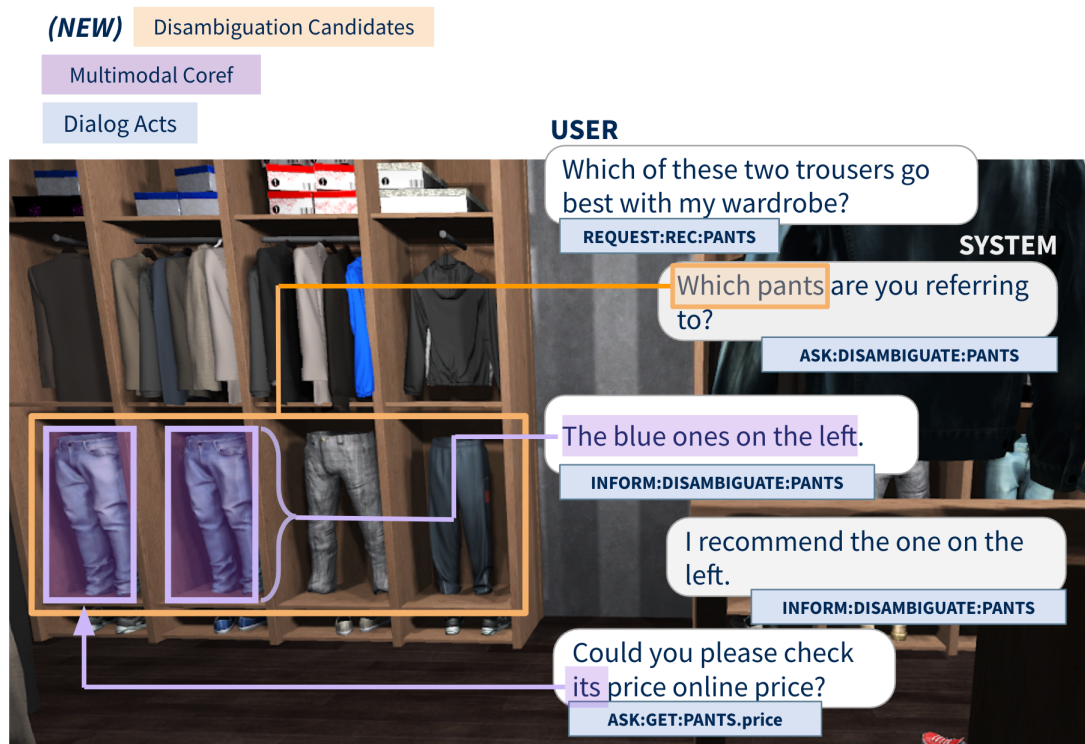
Em outras palavras, o Linear SVC é um SVM com kernel linear que para realizar a classificação dos dados de entrada utiliza uma estratégia multi-classe que compara um contra o resto, em inglês essa estratégia é chamada de *One-Vs-Rest Classifier*. Esta estratégia ajusta o classificador por classes de modo que a classe é ajustada em relação a todas as outras classes para cada classificador.

4.1.2 Escolha das bases de dados

Com relação a coleta de dados para o treinamento do modelo. Ao final da pesquisa e análise citada na seção 3.2.1, duas bases de dados foram escolhidas, a SIMMC - *Situated Interactive MultiModal Conversations* (Moon et al., 2020), e a SIMMC 2 (Kottur et al., 2021), ambos no contexto de compras. A SIMMC disponha de cerca de 13 mil diálogos humano-humano, contendo ao redor de 169 mil enunciados divididos entre dois domínios: o mobiliário e o de moda (com mais de 6 mil diálogos e mais de 71 mil enunciados). Já a SIMMC 2, contém mais de 11 mil diálogos entre humanos e assistentes virtuais e aproximadamente 117 enunciados no domínio de compras relacionado a moda.

Ambos os conjuntos de dados foram disponibilizados em quatro partes, chamadas *Train*, *Dev*, *Test-Dev* e *Test-Std*. As duas primeiras partes são utilizadas para treinamento e para seleção de hiper-parâmetros e assim por diante, enquanto *Test-Dev* é o conjunto de testes publicamente disponível para medir o desempenho do modelo. *Test-Std* é o segundo conjunto de dados utilizado para avaliação interna do modelo nos desafios da plataforma em que foram disponibilizados e portanto não disponível publicamente.

A figura 4.2 mostra algumas sentenças contidas no conjunto de dados SIMMC 2 e suas respectivas intenções.

Figura 4.2: Ilustração do *dataset* SIMMC 2

Fonte: (Kottur et al., 2021)

4.1.3 Análise dos modelos de aprendizado de máquina escolhidos

Todos os modelos de aprendizado de máquina foram treinados com ambas as bases de dados escolhidas. As bases de dados passaram por processos de pré-processamento e limpeza como descrito na seção 3.2.2. A seguir estão os resultados obtidos de forma detalhada por todos os modelos analisados com cada base de dados.

Tabela 4.1: Resultados obtidos utilizando o modelo LSTM e a base de dados SIMMC ordenados pela acurácia

Remover Símbolos	Remover Stop Words	Vocabulary	Acurácia
Falso	Falso	512	0.858
Falso	Falso	128	0.857
Verdadeiro	Falso	256	0.857
Verdadeiro	Falso	512	0.854
Falso	Falso	256	0.854
Verdadeiro	Falso	128	0.847
Falso	Verdadeiro	256	0.827
Falso	Verdadeiro	512	0.826
Falso	Verdadeiro	128	0.825
Verdadeiro	Verdadeiro	512	0.774
Verdadeiro	Verdadeiro	256	0.771
Verdadeiro	Verdadeiro	128	0.770

Tabela 4.2: Resultados obtidos utilizando o modelo LSTM e a base de dados SIMMC 2 ordenados pela acurácia

Remover Símbolos	Remover Stop Words	Vocabulary	Acurácia
Verdadeiro	Falso	128	0.913
Verdadeiro	Falso	512	0.912
Verdadeiro	Falso	256	0.910
Falso	Falso	512	0.910
Falso	Falso	256	0.907
Falso	Falso	128	0.902
Falso	Verdadeiro	512	0.890
Falso	Verdadeiro	256	0.886
Falso	Verdadeiro	128	0.886
Verdadeiro	Verdadeiro	512	0.874
Verdadeiro	Verdadeiro	128	0.872
Verdadeiro	Verdadeiro	256	0.868

As tabelas 4.1 e 4.2 mostram os resultados obtidos ao utilizar a rede neural LSTM para a classificação de intenções. Como já citado anteriormente foram testados a utilização de alguns processos de pré-processamento, neste caso a remoção de símbolos e *stop Words*. Nessas tabelas, a coluna *Vocabulary* representa o valor da dimensionalidade do espaço de

saída que variou entre 128, 256 e 512.

A tabela 4.3 mostra a matriz de confusão para o melhor resultado do modelo LSTM entre as configurações e bases de dados testadas, ou seja, o modelo com a remoção dos símbolos, sem a remoção de *stop words*, *vocabulary* de valor 128 e utilizando a base de dados SIMMC 2.

Tabela 4.3: Tabela com a matriz de confusão para o modelo LSTM com melhor resultado de acurácia dentre as duas bases de dados

758	1	2	9	3	164	3
5	830	0	1	6	6	7
1	1	833	7	2	1	7
6	4	9	765	4	3	107
3	16	1	2	1302	7	9
107	7	1	8	5	641	5
4	4	6	191	5	4	2736

Para o modelo BiLSTM, como foi feito com a rede neural LSTM, foram testados alguns valores para a dimensionalidade utilizada no modelo e também a remoção de *stop Words* e símbolos na fase de pré-processamento. As tabelas 4.4 e 4.5 mostram os resultados obtidos utilizando as bases de dados SIMMC e SIMMC 2 respectivamente.

Tabela 4.4: Resultados obtidos utilizando o modelo BiLSTM e a base de dados SIMMC ordenados pela acurácia

Remover Símbolo	Remover Stop Words	Vocabulary	Acurácia
Falso	Falso	256	0.863
Falso	Falso	512	0.856
Falso	Falso	128	0.855
Verdadeiro	Falso	512	0.855
Verdadeiro	Falso	256	0.851
Verdadeiro	Falso	128	0.849
Falso	Verdadeiro	512	0.828
Falso	Verdadeiro	256	0.826
Falso	Verdadeiro	128	0.824
Verdadeiro	Verdadeiro	128	0.780
Verdadeiro	Verdadeiro	512	0.775
Verdadeiro	Verdadeiro	256	0.775

Tabela 4.5: Resultados obtidos utilizando o modelo BiLSTM e a base de dados SIMMC 2 ordenados pela acurácia

Remover Símbolo	Remover Stop Words	Vocabulary	Acurácia
Verdadeiro	Falso	128	0.911
Falso	Falso	512	0.910
Falso	Falso	128	0.909
Verdadeiro	Falso	256	0.905
Verdadeiro	Falso	512	0.904
Falso	Falso	256	0.903
Falso	Verdadeiro	128	0.889
Falso	Verdadeiro	256	0.888
Falso	Verdadeiro	512	0.887
Verdadeiro	Verdadeiro	512	0.871
Verdadeiro	Verdadeiro	128	0.871
Verdadeiro	Verdadeiro	256	0.871

A tabela 4.6 expõe a matriz de confusão para o melhor resultado do modelo BiLSTM, logo, o modelo com a remoção dos símbolos, sem a remoção de *stop words*, *vocabulary* de valor 128 e utilizando a base de dados SIMMC 2.

Tabela 4.6: Tabela com a matriz de confusão para o modelo BiLSTM com melhor resultado de acurácia dentre as duas bases

797	0	4	6	5	126	2
6	832	0	0	4	5	8
0	1	832	10	2	4	3
11	4	9	776	4	3	91
4	18	2	1	1300	6	9
156	6	2	6	4	598	2
7	6	14	216	6	6	2695

As tabelas 4.7 4.8 logo abaixo demonstram os resultados obtidos ao utilizar o modelo Bert e as bases de dados SIMMC e SIMMC 2 respectivamente, variando o valor de *Dropout*. O Dropout trata-se de uma técnica de inserção de incerteza utilizada para prevenir sobre-ajustamento e de forma resumida o mesmo funciona zerando aleatoriamente uma percentagem de neurônios nas camadas da rede neural. Ele foi utilizado aqui por demonstrar melhorar os resultados.

Tabela 4.7: Resultados obtidos utilizando o modelo Bert e a base de dados SIMMC ordenados pela acurácia

Dropout	Acurácia
0.15	0.619
0.20	0.619
0.25	0.619
0.30	0.619
0.10	0.618

Tabela 4.8: Resultados obtidos utilizando o modelo Bert e a base de dados SIMMC 2 ordenados pela acurácia

Dropout	Acurácia
0.25	0.937
0.30	0.936
0.15	0.935
0.20	0.933
0.10	0.932

A tabela 4.9 mostra a matriz de confusão referente ao melhor resultado do modelo Bert entre as configurações e bases de dados testadas. O modelo com *dropout* de 0.25 que utiliza a base de dados SIMMC 2 foi o modelo Bert com melhor valor de acurácia dentre os observados.

Tabela 4.9: Tabela com a matriz de confusão para o modelo Bert com melhor resultado de acurácia dentre as duas bases

865	2	1	8	4	57	3
8	836	0	1	7	2	1
0	4	830	12	2	1	3
2	1	9	816	0	0	70
2	19	2	3	1310	2	2
206	2	2	0	6	558	0
2	3	6	79	1	4	2855

Nas tabelas 4.10 e 4.11 é possível verificar os resultados obtidos através do uso do modelo Linear SVC utilizado. O parâmetro C representa o parâmetro de regularização que trata-se de um controle sobre os parâmetros de ajuste, a intensidade da regularização

é inversamente proporcional ao valor de C . Em outras palavras, C é a penalidade associada as instâncias que são classificadas erradas, ou seja, quanto maior o C , mais ajustado o modelo vai ser aqueles dados e consequentemente teremos menos erros de classificação, porém, aumentamos a possibilidade de sobreajustamento, logo teremos modelos menos generalizados.

Tabela 4.10: Resultados obtidos utilizando o modelo SVC e a base de dados SIMMC ordenados pela acurácia

Remover Símbolo	Remover Stop Words	C	Acurácia
Falso	Falso	0.1	0.865
Falso	Falso	0.5	0.865
Verdadeiro	Falso	0.1	0.865
Verdadeiro	Falso	0.5	0.865
Verdadeiro	Falso	1.0	0.864
Falso	Falso	1.0	0.864
Falso	Falso	2.0	0.861
Verdadeiro	Falso	2.0	0.861
Verdadeiro	Falso	5.0	0.859
Verdadeiro	Falso	10.0	0.859
Verdadeiro	Falso	20.0	0.859
Falso	Falso	5.0	0.859
Falso	Falso	10.0	0.859
Falso	Falso	20.0	0.859
Falso	Falso	100.0	0.855
Verdadeiro	Falso	100.0	0.855
Falso	Verdadeiro	0.5	0.819
Verdadeiro	Verdadeiro	0.5	0.819
Falso	Verdadeiro	0.1	0.818
Verdadeiro	Verdadeiro	0.1	0.818
Falso	Verdadeiro	1.0	0.817
Verdadeiro	Verdadeiro	1.0	0.817
Falso	Verdadeiro	2.0	0.814
Verdadeiro	Verdadeiro	2.0	0.814
Falso	Verdadeiro	5.0	0.811
Verdadeiro	Verdadeiro	5.0	0.811
Falso	Verdadeiro	10.0	0.809
Verdadeiro	Verdadeiro	10.0	0.809
Falso	Verdadeiro	20.0	0.808
Verdadeiro	Verdadeiro	20.0	0.808
Falso	Verdadeiro	100	0.807
Verdadeiro	Verdadeiro	100.0	0.807

Tabela 4.11: Resultados obtidos utilizando o modelo SVC e a base de dados SIMMC 2 ordenados pela acurácia

Remove Symbol	Remove Stop Word	C	Accuracy
False	False	5.0	0.938
True	False	5.0	0.938
False	False	2.0	0.938
False	False	1.0	0.937
True	False	1.0	0.937
True	False	2.0	0.937
False	False	10.0	0.936
True	False	10.0	0.936
False	False	20.0	0.935
True	False	20.0	0.935
False	False	0.5	0.934
True	False	0.5	0.934
False	False	100.0	0.931
True	False	100.0	0.931
True	False	0.1	0.925
False	False	0.1	0.925
False	True	2.0	0.904
True	True	2.0	0.904
False	True	1.0	0.903
True	True	1.0	0.903
True	True	5.0	0.903
False	True	5.0	0.903
False	True	0.5	0.902
True	True	0.5	0.902
True	True	10.0	0.900
False	True	10.0	0.900
True	True	20.0	0.896
False	True	20.0	0.896
False	True	100.0	0.890
True	True	100.0	0.890
True	True	0.1	0.886
False	True	0.1	0.886

A tabela 4.3 logo abaixo, mostra a matriz de confusão para o modelo SVC com melhor

resultado obtido entre as configurações e bases de dados testadas, ou seja, o modelo que não removeu os símbolos, que também não removeu *stop words*, com valor 5.0 para o parâmetro C e utilizando a base de dados SIMMC 2.

Tabela 4.12: Tabela com a matriz de confusão para o modelo SVC com melhor resultado de acurácia dentre as duas bases

834	2	2	4	1	94	3
6	833	0	2	8	4	2
1	1	824	10	5	5	6
5	0	4	841	0	1	47
2	9	3	3	1319	3	1
146	4	1	1	2	626	1
4	3	10	121	2	3	2807

Como citado anteriormente na etapa de metodologia, no modelo de dados SVC também foi realizado a técnica “Word to Vector”, o resultado obtido é mostrado logo abaixo:

Tabela 4.13: Comparativo da acurácia do modelo SVC utilizando a técnica “Word to Vector”

Utilizando Word2Vec	Acurácia Final
Não	0.938
Sim	0.928

Importante ressaltar que todos os modelos aqui testados passaram por processos de calibração dos parâmetros, ou seja, os parâmetros dos modelos foram ajustados de forma a se obter o melhor resultado. Todos os modelos passaram por processos manuais de calibração dos parâmetros com exceção do modelo SVC em que foi utilizado o método *CalibratedClassifierCV* da biblioteca scikit learn que usa um processo de validação cruzada para estimar os parâmetros do classificador.

A tabela 4.14 contém os resultados finais com relação a acurácia para cada modelo de aprendizado de máquina escolhido e treinado com ambas as bases de dados.

Dois pontos que chamam a atenção são a que todos os modelos testados tiveram melhores resultados utilizando a base de dados SIMMC 2, mesmo que ambas as bases tenham passado pelo mesmo pré-processamento dos dados, o que aponta para uma melhor qualidade da versão 2.0 da SIMMC. Outro ponto importante, é que em todos os modelos testados, o melhor resultado obtido não utilizou a etapa de remoção das *stop words*, o que pode apontar para uma perda de significado que é importante para a classificação de intenções em uma sentença

Tabela 4.14: Tabela com melhor resultado para cada modelo utilizando as duas bases ordenada pela acurácia

Modelo avaliado	Base de dados utilizada	Acurácia Final
SVC	SIMMC 2.0	0.938
BERT	SIMMC 2.0	0.937
LSTM	SIMMC 2.0	0.913
BiLSTM	SIMMC 2.0	0.911
SVC	SIMMC	0.865
BiLSTM	SIMMC	0.863
LSTM	SIMMC	0.858
BERT	SIMMC	0.619

Após todo o processo de pré-processamento dos dados, testes e calibração dos modelos, o modelo escolhido para se desenvolver um classificador de intenções foi o SVC. Como pode ser visto na tabela 4.14, o SVC foi o modelo que obteve melhor acurácia dentre todos os modelos testados, embora todos os resultados tenham ficado próximos, em especial o modelo BERT. Foi observado a acurácia e a matriz de confusão de todos os modelos ao serem treinados com as bases de dados propostas, o modelo SVC foi escolhido pois teve melhores resultados com ambas as bases. A figura 4.3 mostra o uso do classificador de intenções desenvolvido.

```

1 > Hi, I want a skirt
2 REQUEST:GET
3
4 > Which of this two skirts is better?
5 REQUEST:COMPARE
6
7 > Please, add them to the cart
8 REQUEST:ADD_TO_CART

```

Figura 4.3: Demonstração de uso do classificador de intenções desenvolvido

Fonte: Do próprio autor

O classificador de intenções desenvolvido foi criado utilizando a linguagem de programação *python* e para o treinamento fez uso da base de dados SIMMC 2.0 (Kottur et al., 2021) na qual disponibiliza cerca de 11 mil diálogos entre usuários e assistentes de diálogos, com aproximadamente 117 mil enunciados no domínio de compras e o modelo de aprendizagem de máquina *SVC* para classificação das intenções.

4.2 Criação de um dataset

4.2.1 Estudo acerca da formação de corpora

Analizando o processo de criação de sistemas de conversação (ou chatbots), mais precisamente a etapa da formação de corpora, como pode ser visto no tópico 2.5, foi realizado um levantamento das maneiras mais utilizadas no contexto acadêmico e no contexto da indústria para coleta de dados.

Como resultado, foi visto que API's com dados abertos de redes sociais ou fóruns, coletas manuais através de crawler's, entrevistas e chats que simulam situações reais na conjuntura em que o chatbot está inserido, são os métodos mais comumente utilizados.

4.2.2 Simulação de conversa entre lojista e cliente

Experimento I

O primeiro experimento foi realizado com 8 pessoas ao todo, com 4 pessoas fazendo o papel de lojista e 4 pessoas realizando o papel de cliente. O experimento durou cerca de 30 minutos e foram coletadas 123 mensagens ao todo entre as enviadas pelos clientes e pelos vendedores.

Como resultado desse primeiro experimento, após a limpeza dos dados, foram obtidas 111 mensagens. A partir dessas mensagens foram extraídas 16 ações, são elas: cumprimentar, apresentar produto, perguntar sobre preferência do cliente, perguntar sobre produto ou estoque da loja, confirmar, elogiar, negar, perguntar sobre entrega da loja, apresentar forma de pagamento, pedir recomendação, oferecer promoção, pedir desculpas, apresentar tendência, apresentar preferência de produto, perguntar preferência de pagamento do cliente, agradecer. As cinco ações que mais apareceram nas sentenças estão listadas na tabela 4.15.

Tabela 4.15: 5 ações mais recorrentes nas frases extraídas da simulação 1

Parâmetros	Nº de sentenças
Confirmar	25
Apresentar produto	24
Perguntar preferência de produto	24
Apresentar preferência de produto	24
Elogiar	12

Além das ações citadas, foram extraídas também 6 tipos diferentes de produtos: saia, calça, camisa, moletom, blusa e vestido, também foram extraídas 7 características dos

produtos, dentre elas o tecido, a marca, o tamanho e etc, e para cada característica seus valores, por exemplo, para tamanho foi pego os valores: XG, P, G, entre outros.

A principal dificuldade encontrada durante esse experimento foi relacionada as pessoas com o cargo de vendedor, onde foi percebido que sempre chegou um ponto em que as conversas não pareciam tão naturais, isso se deu principalmente ao fato das pessoas que participaram desse experimento não serem profissionais da área, mesmo que saibam de forma geral como o processo de venda funciona e que também tenham recebido algumas orientações antes do início do experimento.

Experimento II

Já o segundo experimento foi realizado com 14 pessoas, sendo que dessa vez houve uma maior rotação de função entre elas, ou seja, algumas pessoas participaram de mais de uma conversa exercendo em cada conversa uma função diferente, também foi-se orientado a terem conversas mais objetivas. Neste experimento foram coletadas 193 mensagens ao todo.

Após a realização da limpeza de dados, conforme feito no primeiro experimento, foram extraídas 181 mensagens no total. E além das ações extraídas anteriormente, foram acrescentadas as ações: perguntar sobre pagamento, perguntar sobre características do produto, despedir, pedir confirmação do cliente, perguntar endereço de entrega, apresentar endereço de entrega. Além disso foi acrescido mais uma característica relacionada aos produtos: o preço, que não havia sido mencionado no experimento I.

Tabela 4.16: 5 ações mais recorrentes nas frases extraídas da simulação 2

Parâmetros	Nº de sentenças
Confirmar	41
Perguntar preferência de produto	41
Negar	34
Apresentar produto	32
Apresentar preferência de produto	29

Nesse experimento devido a troca mais frequente de papéis entre os participantes do experimento e a maior objetividade com que foi conduzido as conversas entre os mesmos, foi percebido uma maior dinamicidade quanto as falas destes, em ambos os papéis. Porém, a falta de experiência real dos participantes ainda foi algo notável a partir de certa parte das conversas ao lidar com diferentes cenários em que os mesmos não estavam preparados, tornando as conversas menos naturais.

Resultados gerais

Em linhas gerais, ambos os experimentos foram realizados de forma satisfatória e com eles foram coletados 292 sentenças ao todo. Essas sentenças foram agrupadas em intenções gerais de acordo com a ação extraída, por exemplo, ações relacionadas a perguntar como "perguntar preferência do cliente" ou "perguntar sobre produto da loja", foram agrupadas em uma intenção única: perguntar, outras ações que possuíam poucos dados, ou seja, menos de 4 sentenças, e que não se encaixavam com nenhuma outra ação em uma intenção mais geral, foram removidas. As intenções e também a quantidade de frases classificadas em cada uma delas pode ser vista na tabela 4.17:

Tabela 4.17: Quantidade de sentenças coletadas através dos experimentos por intenção

Intenções	Nº de sentenças
Cumprimentar	17
Informar	93
Perguntar	115
Confirmar	33
Negar	25
Solicitar	9

4.2.3 Coleta de dados reais

Aqui nesta etapa foram realizadas coletas de conversas reais entre lojistas e clientes através das plataformas WhatsApp e Instagram e uma parceria com a loja *My Trend*. As sentenças coletadas nessa etapa foram classificadas usando as intenções resultantes dos experimentos na plataforma de simulação de conversas entre lojista e cliente da seção 4.2.2. Os detalhes das coletas e os resultados obtidos estão descritos nas próximas seções.




Figura 4.4: Captura de tela do site oficial da loja virtual My Trend

Fonte: Do próprio autor

Plataforma WhatsApp

Na plataforma WhatsApp foram coletadas 132 sentenças ao todo sendo que 4 sentenças foram descartadas no processo de limpeza. A quantidade de sentenças classificadas por intenções pode ser vista na tabela 4.18:

Tabela 4.18: Quantidade de sentenças coletadas no WhatsApp classificadas por intenção

Intenções	Nº de sentenças
Cumprimentar	7
Informar	37
Perguntar	56
Confirmar	9
Negar	4
Solicitar	15

Como a aplicação WhatsApp não é um ambiente controlado e o mesmo possui muitos recursos a mais quando comparado com a plataforma de chat desenvolvida, como o envio de áudios, imagens e emojis, houve uma dificuldade em obter tais dados através do Web Scraper desenvolvido, que não era capaz de extrair e renderizar esses tipos de dados e até mesmo corrompia sentenças que continham certos emojis, sendo essa a principal dificuldade nesta etapa.

Plataforma Instagram

Já na aplicação Instagram foram coletadas 193 sentenças. Após o processo de limpeza e descarte, permaneceu-se com 187 sentenças ao todo. A quantidade de frases por intenção está exposto na tabela abaixo:

Tabela 4.19: Quantidade de sentenças coletadas no Instagram classificadas por intenção

Intenções	Nº de sentenças
Cumprimentar	2
Informar	87
Perguntar	79
Confirmar	13
Negar	0
Solicitar	7

As mesmas dificuldades relatadas para a plataforma WhatsApp foram vistas aqui, frases que continham imagens, videos, audios, emojis e até mesmo links tiveram que ser descartadas, pois durante a coleta esses dados corrompiam as frases em que estavam inseridos ou não eram coletados fazendo com que as sentenças perdessem o seu sentido.

4.2.4 Formação do corpora com os dados coletados

Como já citado anteriormente, todos os dados coletados através dos experimentos com a simulação de conversas entre lojistas e clientes, assim como os dados reais coletados através da parceria com a loja virtual *My Trend* serviram para a formação de um dataset com 605 frases disposto no apêndice A. Essa quantidade foi obtida após serem removidos duplicatas e a tabela a seguir mostra a quantidade final de sentenças classificadas por intenção:

Tabela 4.20: Quantidade de sentenças coletadas classificadas por intenção

Intenções	Nº de sentenças
Cumprimentar	24
Informar	219
Perguntar	252
Confirmar	56
Negar	26
Solicitar	28

5

Conclusões

5.1 Considerações Finais

No presente trabalho foi apresentado um estudo comparativo a cerca de técnicas para classificação de intenções para chatbots no contexto de e-commerce, mais especificamente no setor de moda. Ao final do estudo comparativo foi-se desenvolvido um classificador de intenções, e o desenvolvimento desse classificador se deu a partir da linguagem python, do modelo de aprendizagem de máquina SVC e da base de dados SIMMC 2.

Uma análise comparativa entre quatro modelos de aprendizagem de máquina, sobre dois conjuntos de dados pertencentes a conjuntura abordada, foi realizada, a fim de permitir a extração de métricas e a realização da tomada de decisão a respeito de qual modelo de aprendizado de máquina seria escolhido para a construção do classificador de intenções objetivado.

Ademais, como objetivo secundário, este trabalho também propôs a criação de uma base de dados com conversas entre lojistas e clientes, em português. Com esse propósito, um chat foi desenvolvido utilizando tecnologias e conceitos de engenharia de software, onde foi realizado uma simulação de conversas entre profissionais do varejo de roupas e consumidores. Além disso, houve também a coleta de conversas reais entre ambos os participantes em mídias sociais como o *Instagram* e o *WhatsApp*.

A principal dificuldade encontrada foi relacionada a formação do conjunto de dados, já que na metodologia proposta onde se usou um chat para coleta de dados não houve a participação de um profissional da área, o que daria maior credibilidade e fluidez nos experimentos. Porém, como citado logo acima, essa dificuldade foi sanada ao se fechar a parceria com a loja *My Trend*, onde houve a incrementação da base através do acesso às conversas reais entre lojistas e clientes, além da validação das conversas realizadas através do chat.

Através dos resultados apresentados é possível afirmar que todos os objetivos foram alcançados de forma satisfatória, já que além dos conhecimentos obtidos na área de inteligência artificial e engenharia de software que muito acrescentaram para a formação do autor, a ferramenta de classificação de intenções que foi projetada e construída realiza o que foi proposto e uma base de dados como foi colocado, foi disponibilizada no apêndice do trabalho aqui proposto.

5.2 Trabalhos futuros

Como trabalhos futuros, dado o desenvolvimento do classificador de intenções em questão, a aplicação do mesmo em um chatbot para uso real é esperada. Além disso, o aumento de dados na base de dados em português entre varejistas e clientes com o uso do chat desenvolvido por profissionais reais do mercado e o acesso a mais dados coletados em lojas brasileiras atuantes no mercado online, são os focos principais para o futuro.

Apêndice A

Base de dados gerada através do trabalho desenvolvido

```
1 {
2   "intents": [
3     {
4       "tag": "CUMPRIMENTAR",
5       "patterns": [
6         "Olá",
7         "Oi",
8         "Olá. Tudo bem?",
9         "Oi, Bruna",
10        "Vendido, muito obrigada e volte sempre",
11        "O prazer é todo nosso! Muito obrigada e uma boa vida!
12        ↪ :)",
13        "De nada. Volte sempre.",
14        "Eu quem agradeço e pode deixar que irei voltar mesmo.
15        ↪ Tchau",
16        "boa tarde e volte sempre!",
17        "ótimo, apesar de ser um tamanho maior, é uma blusa
18        ↪ soltinha, vai ficar linda em você",
19        "Muito obrigada, tenha uma ótima tarde",
20        "Então ta ok, até mais",
21        "ta bom brigado flw",
22        "Obrigada pela preferência, tenha uma ótima noite!",
23        "Ola",
24        "Boa tarde.",
```

```

22         "Oi",
23         "Bom dia",
24         "Agradecemos o seu contato...Aguarde um instante que já
↳      vamos lhe atender, enquanto isso confira nosso
↳      catálogo, basta clicar aqui na nossa foto em seguida
↳      ver catálogos",
25         "Oi.",
26         "Olá, como está?",
27         "Mas vou querer ele, ok?",
28         "Olá, agradecemos o seu contato. Como podemos ajudar
↳      você?",
29         "Olá qual o seu nome?",
30         "Obrigada"
31     ]
32 },
33 {
34     "tag": "INFORMAR",
35     "patterns": [
36         "Tudo sim. Eu estou procurando uma saia pra minha irmã",
37         "o maior que tiver, XG eu acho que dá.",
38         "A preferência é algodão",
39         "As incríveis saias que eu vi na vitrine",
40         "Só trabalhamos com gucci.",
41         "Nós temos! Temos, também, em algumas opções de cores e
↳      estampas.",
42         "Boa pergunta... Acho que P",
43         "Amarelo, vermelho, verde, rosa, preta, bege, nude,
↳      marrom e laranja. Algumas das nossas estampas são:
↳      Listrada, floral, estampa e zebra.",
44         "Preta e roxa",
45         "Enviamos sim, inclusive, enviamos para o exterior. Então,
↳      é só dizer o seu endereço que o resto é com a gente!
↳      :)",
46         "Acho que o tamanho P tá bom",
47         "listrada, floral, estampada, zebra, amarelo, azul,
↳      vermelho, roxa, rosa, branca, laranja, nude",
48         "Essas cores estão em falta, mas a rosa deve ficar linda
↳      em você",
49         "Vou querer dois moletons, um rosa e outra floral",

```

50 "Cartão de crédito, cartão de débito, cheques e boletos!
↳ Porém, não se preocupe com isso ainda, eu ainda posso
↳ te apresentar mais algumas coisas... Temos camisas de
↳ manga longa e regular, com ótimas cores. Me diga uma
↳ cor ou estampa que você gostaria.",
51 "Infelizmente preto não vou ter, mas vou ter essa saia
↳ marrom maravilhosa",
52 "Temos saias também, modelos regular, justo, curta e
↳ evase",
53 "Acho que branco combina mais",
54 "Vermelha",
55 "Com certeza! O tecido é feito à mão e com detalhes
↳ exclusivos para cada cliente!",
56 "Justo",
57 "Um moletom M e outro GG",
58 "tenho não? mas essa de modelagem justa está sendo muito
↳ vendida",
59 "Gosto de estampas floridas, tulipas de preferência",
60 "Pedido anotado! Sobre as saias, temos as mesmas cores do
↳ moletom, só subir a conversa.",
61 "Então pode ser justa mesmo",
62 "Tudo certo! Então a compra de uma calça jeans com
↳ estampa floral/tulipas e uma camisa de manga longa,
↳ tecido egípcio, gola em V e tamanho PP. Qual será a
↳ forma de pagamento? Assim efetuamos a compra. :)",
63 "280 reais, mas está o mesmo preço, tanto o modelo de
↳ cintura alta quanto o de cintura baixa",
64 "Vou embalar; vai ficar R\$40,00 e pode dividir em até 3
↳ vezes sem juros",
65 "Ótima escolha! Temos tamanhos P, M e GG",
66 "Vou querer dividir em 2 vezes",
67 "Ta ótimo, as peças parecem ser maravilhosas, porém, no
↳ momento não disponho de condições financeiras para
↳ efetuar o pagamento, devido à crise. Foi um prazer,
↳ boas vendas!",
68 "Alta",
69 "Algodão",
70 "Leva uma de couro também, vai combinar com a blusa
↳ floral!",

71 "Se você comprar essa blusa xadrez, posso deixar a saia e
↪ ela pela metade do preço",
72 "Deixe-me ver com meu gerente....Como eu sei que sua irmã
↪ é uma pessoa bem especial, meu gerente permitiu que
↪ eu ofereça essa camisa de seda, que está super na
↪ moda, e a saia que você está pedindo, pro apenas 150
↪ reais. O que você acha?",
73 "Amém!",
74 "Parcelado",
75 "Ok, pedido confirmado. Obrigada por comprar conosco!",
76 "Tá bom, ó aqui o seu pedido pode passar no caixa, só
↪ avisar lá que você vai receber o seu desconto",
77 "A vista",
78 "No momento, os vestidos estão em falta",
79 "infelizmente não, apenas P, M e GG",
80 "Então acho que vou querer M",
81 "até 50 apenas em 3 vezes, acima de 100 reais até 5
↪ vezes",
82 "hmmm... vai ser no cartão mesmo",
83 "Deu 50 + 10 de frete, tudo bem?",
84 "Prontinho, o seu pedido vai sair daqui mais ou menos 1h,
↪ está bem?",
85 "Infelizmente não senhora, temos apenas jeans, algodão e
↪ couro",
86 "poxa, acho que vou querer o couro",
87 "Que excelente escolha, a versão de couro tem sido
↪ bastante buscada recentemente",
88 "Passamos sim, para você que tem cara de cliente fiel a
↪ gente parcela até em 20x",
89 "Temos sim, temos de todos os gostos, certamente você irá
↪ arrasar em qualquer lugar que for com nossos
↪ produtos",
90 "Infelizmente, nós não temos calça, vendeu tudo no ano
↪ novo, mas temos diversas blusas. Tem interesse em
↪ alguma?",
91 "Não temos no momento. E que tal um moletom?",
92 "M",
93 "Quero compra um calça ta ligado",
94 "O tamanho M está indisponível.",

95 "Infelizmente, não está disponível.",
96 "O tamanho G está disponível.",
97 "Não está disponível a cintura intermediária.",
98 "Dinheiro",
99 "A forma de pagamento será boleto bancário.",
100 "Vestido preto está disponível, porém a cintura baixa
↪ não.",
101 "poxa vida, moça, eu queria tanto um cintura baixa ;-;",
102 "Não, apenas jeans e seda.",
103 "Infelizmente, não vendemos blusa.",
104 "vou querer só a calça então",
105 "floral xadrez estampada zebra azul verde roxa preta bege
↪ marrom",
106 "vou querer uma xadrez, vou ficar divina",
107 "12 vezes no cartão com juros.",
108 "Desconto de 20% no uso do cartão da loja.",
109 "O tamanho é PP",
110 "Sim, na primeira compra com cartão, é oferecido 30% de
↪ desconto nas compras acima de 100 reais.",
111 "Outra grande vantagem é o parcelamento de até 24 vezes
↪ sem juros.",
112 "Total da compra: 870,99. Forma de pagamento: cartão da
↪ loja.",
113 "Eu quero um GG, é que eu sou meio cheinha hihhi",
114 "é, moço, vida difícil, viu. Eu quero manga curta, tá
↪ fazendo muito calor, vc tem?",
115 "Divido 3 vezes sem juros",
116 "Ai sim!!!! já conquistou uma cliente fixa viu",
117 "Gostaria de uma calça skinny",
118 "No momento, não temos calça skinny, apenas temos calça
↪ slim e reta no estoque. Você gostaria de ver esses
↪ modelos?",
119 "Temos listrada, floral, estampada, zebra, azul, verde,
↪ rosa, branca, laranja, marrom e nude. Alguma é do
↪ seu interesse?",
120 "Sim. Gostaria da zebrada, tamanho M.",
121 "Gostaria da cor vermelha no tamanho P, por favor.",
122 "Manga longa na cor preta",
123 "Boa tarde. Estou em busca de uma calça tamanho P.",

124 "Tamanho M na cor azul, por favor.",
125 "Crédito",
126 "Certo. O pedido está sendo processado",
127 "Certo, o frete fica R\$15.",
128 "No momento não temos blusa. Quer da uma olhada nas
↪ camisas?",
129 "Temos floral, estampada, camuflada e algumas outras.
↪ Interessa alguma?",
130 "Tamanho G",
131 "Últimos dias de promoção Leve 3 peças e pague apenas 2",
132 "Já separei pra vc",
133 "Gostei desse azul",
134 "boa noite deu certo sua compra",
135 "No site você encontra todas as informações do produto.
↪ Se tiver alguma dúvida pode me chamar",
136 "Vou te mandar os links",
137 "Todo o site com 30% a 50% off",
138 "Tem no tamanho 38?",
139 "Ele é 38 mas veste 40/42",
140 "Eita acho que é grande",
141 "Estou precisando de uma calça de alfaiataria",
142 "Tenho essa cor P",
143 "P",
144 "Tipo, tamanho normal",
145 "Ahh mas eu sou alta por isso fica mais curta em mim",
146 "Ela é modelo Skinny",
147 "Tenho essas outras",
148 "Tamanho P",
149 "Chega sim essa semana a outra chega",
150 "E te aviso",
151 "A minha foi M",
152 "Você geralmente veste igual",
153 "Acho que M mesmo",
154 "Se vai ficar mais comprida",
155 "Eu vou querer provar os dois",
156 "Põe só amarelo",
157 "Liso laranja e verde",
158 "só tenho 42 agora",
159 "Todas as da imagem",

160 "Exceto a branca",
161 "Apenas por encomenda",
162 "Chega com 1 semana",
163 "Calça bengaline 89,90",
164 "Te mandar o link para você ver as cores",
165 "Pink verde e azul são lindas",
166 "Olá, 149,90",
167 "Que bom que gostou da nossa calça, ela é maravilhosa,
↪ vamos te enviar o link de compra se tiver mais alguma
↪ dúvida só nos chamar tá? Boas compras",
168 "Imagem real da peça",
169 "Quero passar e provar",
170 "Uso 38/40",
171 "Seria a M",
172 "Só temos no azul e terra",
173 "Com pedras tenho G mas a forma é pequena",
174 "Essa de trico só a 1 cor",
175 "Oi Vou conferir se ainda tenho seu tamanho",
176 "Amei esse pena que é sem mangas",
177 "Temos essas peças com mangas",
178 "Levo amanhã",
179 "Minha filha está precisando de calça",
180 "Amei a blusa e a calça",
181 "Ela veste 38",
182 "280 qualquer modelo Skinny",
183 "Tenho essas ainda em estoque",
184 "Novas peças chegam até o final do ano",
185 "Tenho P e M",
186 "P Com sou baixinha as vezes o M fica meio grande",
187 "Levo os dois para você provar",
188 "Amanhã tô lotada a tarde. Vou tentar ir pela manhã",
189 "Moletom",
190 "Seria tamanho G",
191 "G eu só tenho essas duas opções em loja",
192 "Coral liso MIDI",
193 "E o vermelho listrado longo",
194 "Boa noite, tam U veste até um 40",
195 "Custa 79,90",
196 "Visto 42 dependendo da forma 44 que pena",

197 "Estamos tendo problema com fornecedores. A maioria das
↪ peças estão vindo tam U com forma pequena",
198 "Mostarda e rosinha",
199 "São tam U veste um M",
200 "Vou te mandar as fotos",
201 "Elas vestem P",
202 "30,00 cada",
203 "Tam U. Custa 79,90",
204 "Vou te mandar o link, lá tem todas as informações",
205 "Tam U e tá custando 99,90",
206 "Veste até 44",
207 "G e tem outras cores",
208 "Vi no site obrigada",
209 "Olá tudo bem? Esse modelinho só veste até 308/40",
210 "É lindo",
211 "Tá custando 129,90",
212 "Mulher esse que provei é o G",
213 "Vou tirar um tempinho pra ir na loja",
214 "Eu gostaria de comprar uma camisa",
215 "Atualmente temos essas opções de peças em nosso
↪ catálogo",
216 "Visto M",
217 "Atualmente está em falta, semana que vem está chegando
↪ novas peças",
218 "Temos apenas uma peça desse vestido",
219 "Na cor verde mesmo",
220 "Tenho um flare da Bebelá 44 que veste 42 que está por
↪ 156 reais a vista",
221 "Essas são as peças disponíveis",
222 "Não temos modelos de bermudas",
223 "Apenas modelos de calças",
224 "Não temos bermudas apenas calças",
225 "Tenho uma sainha com shortinho 38 mas veste 40",
226 "Esse só tenho na cor do meio com laranja de 69,90",
227 "Só tem preto",
228 "Preto temos até 42/44",
229 "Boa noite, recebemos o novo modelo na cor salmão",
230 "Temos o preto",
231 "Eu tenho esses modelos também",

```

232         "Achei um blusa dessa cor",
233         "Também tenho esse modelo",
234         "Esse modelo não temos mais",
235         "Laranja",
236         "Bom dia. Tenho interesse nas calças",
237         "Olá tenho uma colega que ficou interessada nas calças",
238         "Ela se interessou pela mesma da minha flare",
239         "Ela é 38, porém eu visto 40",
240         "Queria esse look da foto",
241         "Quero listrado",
242         "Achei linda",
243         "Queria um vestidinho curto",
244         "levamos até você",
245         "Podemos parcelar",
246         "Aceitamos cartão, pix e dinheiro a vista",
247         "Custa 149,90 mas está na promoção por 99,90",
248         "Custa 120,00",
249         "Desculpa a demora em responder hoje",
250         "Já mando o link de pagamento",
251         "Vou mostrar a ela",
252         "Bom dia, se não der certo trocamos",
253         "Te mando já as fotos",
254         "Podemos combinar para você provar",
255         "Te mandamos foto já"
256     ]
257 },
258 {
259     "tag": "PERGUNTAR",
260     "patterns": [
261         "tenho saias para vender. Alguma preferência de tecido?",
262         "Tudo bem? Posso te ajudar a melhorar seu estilo! O que
        ↳ você quer comprar hoje? Calça, camisa?",
263         "Só tem saias?",
264         "Tenho moletoms também! não gosta de saias?",
265         "Sim! tem calça jeans?",
266         "Temos! Qual é o seu tamanho?",
267         "Não tenho interesse em saias, que marcas de moletom vc
        ↳ tem?",
268         "O que lhe trás em nossa maravilhosa loja?",

```

269 "Qual o tecido da saia que ela gosta?",
270 "E qual o tamanho que ela veste?",
271 "Quais as cores?",
272 "Você tem algum moletom feito 100% de algodão?",
273 "Maravilha, você fala das saias de seda?",
274 "Sim. Temos de algodão e de seda, caso também goste deste
↪ material. Alguma preferência de cor?",
275 "Eu tenho o tamanho P, G e XG quer dar uma olhada para
↪ tentar ver se você reconhece o tamanho dela?",
276 "Quais são as opções?",
277 "Vocês enviam pra todo o Brasil?",
278 "Top; quer provar quais cores?",
279 "Entendi. Quais as formas de pagamento?",
280 "Ótimo. Qual a cor que ela gosta?",
281 "Ela tem muita roupa preta, o que você recomenda?",
282 "Qual a cor da sua blusa?",
283 "Ótimo, tenho essa saia branca aqui. Qual a modelagem que
↪ ela veste? justo, reto, evase.",
284 "Tá, vou levar também uma saia evase. Quais as cores da
↪ saia?",
285 "Então vamos de branco?",
286 "Você tem slim?",
287 "Qual o tipo da modelagem?",
288 "Ótimo! E qual a cor e/ou a estampa da calça jeans? :)",
289 "Maravilha, vou pegar no estoque; tamanho P?",
290 "Aqui, moça; deseja algo mais?",
291 "Vou querer uma de cor nude. Acerca dos tamanhos, quais
↪ as opções?",
292 "Perfeito. Cintura alta?",
293 "Vermelha?",
294 "Depende do valor. Quanto custa?",
295 "Você não teria uma cintura intermediária?",
296 "Então, vou querer uma saia evase vermelha de tamanho M.
↪ Ok?",
297 "Cintura alta ou baixa?",
298 "Temos diversos tipos de tecido. Deseja jeans, algodão,
↪ seda ou couro?",
299 "Como vejo que você é um cara legal, posso lhe oferecer
↪ uma promoçãozinha?",

300 "Não obrigado. Ficou quanto?",
301 "R\$948,53. Deseja pagar à vista ou parcelado?",
302 "Você não poderia só dar um descontinho na saia?",
303 "Perfeito, você vai querer pagar a vista ou no cartão?",
304 "Tudo certo, vai querer dar uma olhadinha em outras
↪ peças?",
305 "Tem certeza? veja esse moletom.. neste tempo frio ele tá
↪ saindo muito. Além de ser lindo",
306 "poxa e camisa?",
307 "tem preta?",
308 "temos, que tamanho vai querer?",
309 "tem P?",
310 "e das outras cores? tem P?",
311 "Qual vai ser a forma de pagamento?",
312 "passa em até quantas vezes no cartão?",
313 "Boa noite, você esta precisando de ajuda com alguma
↪ coisa?",
314 "Boa noite, você tem vestido preto?",
315 "Temos sim, você tem preferencia por algum tecido?",
316 "tem vestido de cetim?",
317 "ai que ótimo. Vocês passam cartão?",
318 "eita, que maravilha, com essa quantidade de parcela acho
↪ que vou querer mais coisa. Você tem uns moletons
↪ babadeiros?",
319 "Boa noite, meu cliente querido. Gostaria de alguma
↪ coisa?",
320 "Boa noite minha vendedora simpática! Gostaria de comprar
↪ uma calça, você tem uma calça azul?",
321 "Não tenho interesse em blusas :(, você tem saias?",
322 "e uma camisa fresquinha ein?",
323 "Eu já tenho camisas.. Vocês tem saias? Elas são mais
↪ arejadas.",
324 "Olá. Boa noite! Em que posso ajudar?",
325 "Qual tamanho desejado?",
326 "Como nao tem",
327 "Tem G entao to engordando",
328 "Que tal uma cintura alta?",
329 "Deseja mais alguma coisa?",
330 "Que tal uma camisa para combinar?",

331 "Sugestão: Camisa tamanho G de algodão de estampa floral
↪ e manga curta.",
332 "Algo mais?",
333 "Que tal um moletom para combinar?",
334 "Sugestão: Moletom tamanho G de seda de estampa marrom e
↪ aberto.",
335 "Como prefere a forma de pagamento?",
336 "Olá. Boa noite! Em que posso ajudar?",
337 "Oi, Boa noite, eu gostaria de um vestido preto cintura
↪ baixa, vc tem?",
338 "então vou querer uma calça. tem reta?",
339 "tem de couro? quero arrasar na night",
340 "De algodão ou couro?",
341 "Gostaria de algo mais?",
342 "marcomoassim, moça? nem uma brusinha",
343 "Que tal uma saia para combinar?",
344 "ai não sei, você tem que cor?",
345 "Que tal um vestido para combinar?",
346 "Como prefere a forma de pagamento?",
347 "você parcela em quantas vezes?",
348 "WTF?????",
349 "Gostaria de adquirir um cartão da loja?",
350 "eu vou ter desconto se fizer um?",
351 "quero mais vantagens, moça, tem desconto pra cliente
↪ novo?",
352 "Olá menina chic, gostaria de comprar algo na minha
↪ loja?",
353 "Olá, tudo bem? Eu gostaria de uma blusa rosa de couro,
↪ vc tem?",
354 "Tempos de quarentena né.. Tudo certo, nos temos esse
↪ tamanho! E a cor e modelagem qual você quer?",
355 "Tenho! Você quer duas?",
356 "Verdade, vou enviar e passar álcool em um tudo.. e o
↪ tipo de pagamento qual você vai querer?",
357 "você divide em quantas vezes sem juros no cartão?",
358 "O que está procurando?",
359 "Qual o tamanho e a cor desejada?",
360 "Quais cores estão disponíveis?",

361 "Ótimo. Gostaria de dar uma olhada nas blusas ou camisas
↪ para acompanhar?",
362 "Sim, você teria uma camisa de seda?",
363 "Sim, alguma preferência de cor e tamanho?",
364 "Ok. Tem interesse em mais algum produto? Temos moletons
↪ e saias disponíveis.",
365 "Não, mas você teria uma blusa tamanho M?",
366 "Não temos manga longa. Teria interesse em mais algum
↪ produto?",
367 "Você teria uma blusa polo, na cor azul?",
368 "Não temos no momento. Serve uma blusa slim?",
369 "Ok. Mais alguma coisa?",
370 "Boa tarde. O que procura??",
371 "Não. Você teria moletons?",
372 "Tenho sim. Qual tamanho e cor você procura?",
373 "Ok. Qual o método de pagamento?",
374 "Boa noite. Procura ajuda com algum produto?",
375 "Não. Você teria moletom?",
376 "Qual o tamanho?",
377 "Qual a numeração dessa calça?",
378 "Tem essa calça 44?",
379 "Quanto custa?",
380 "Olá quanto custa o vestido vermelho?",
381 "Como faço para provar o vestido?",
382 "Quais cores disponíveis?",
383 "Ainda tem o short saia?",
384 "Qual o valor desse conjunto?",
385 "Quais as cores da calça?",
386 "Ainda tem a saia listrada?",
387 "Quais cores?",
388 "Qual o valor dela?",
389 "Também tem o vestido?",
390 "Qual o valor dessa blusa?",
391 "Quais modelos de blusa você tem?",
392 "Valor",
393 "algo que possa ajudar?",
394 "Ainda tem a blusa?",
395 "Olá Como foi de natal arrasou com o vestido?",
396 "Boa noite já conferiu a nova coleção?",

397 "Qual modelo?",
398 "Da calça?",
399 "E o tamanho?",
400 "Tá de quanto?",
401 "Não tem essa cumprida não?",
402 "Você fala da pantalone?",
403 "Só tem essa?",
404 "E vai chegar azul?",
405 "Você acha que a M da em mim?",
406 "A não ser que prefira mais soltinha",
407 "Oi qual o tamanho tem disponível",
408 "E o valor?",
409 "Olá tudo bem?",
410 "Quais opções você tem P?",
411 "Tem olho grego?",
412 "Você é de qual cidade?",
413 "Qual o valor da calça?",
414 "Quanto custa?",
415 "Olá tem loja física?",
416 "Quer marcar um horário amanhã pela manhã?",
417 "Vou olhar a agenda e te confirmo amanhã de manhã. Pode
↪ ser ?",
418 "Bom dia. Temos horário as 13h. Podemos confirmar?",
419 "Bom dia qual o tamanho?",
420 "E pode me mandar fotos das tshirt pequena?",
421 "Ainda tem daquelas c pedraria?",
422 "E ainda tem dessa verde?",
423 "Como eu faço pra provar a calça? A loja física está
↪ funcionando?",
424 "Quer deixar um horário agendado?",
425 "Chegou esses vestidinhos pra nova coleção, você gosta?",
426 "Tem algum desses pra mim?",
427 "Posso deixar reservado?",
428 "Fazem entrega?",
429 "Quais os looks pra fim de ano?",
430 "Ela veste 36 ou 38?",
431 "Quais são as opções?",
432 "Gostou de mais alguma?",
433 "Acabei de fechar meu pedido quando chega?",

434 "Quanto essa última? tô louca pela a dos botões",
435 "Oi quais tamanhos você tem?",
436 "Tá quanto?",
437 "Tá de quanto?",
438 "Quais horários posso passar aí?",
439 "Gostou de mais alguma peça?",
440 "Ele é malha ou um tecido estilo moletom?",
441 "Quais as peças em promoção?",
442 "Gostou de algo?",
443 "Qual o preço das peças em promoção?",
444 "Ainda tem peças de 10,00?",
445 "Qual tamanho seria? podemos te enviar alguns modelos
↪ para você experimentar",
446 "Você tem algum modelo na cor vermelha?",
447 "Olá qual o tamanho pra esse vestido?",
448 "Bom dia e essa calça?",
449 "Qual seria seu tamanho?",
450 "Deram certo as peças?",
451 "Será q cabe em mim? kkkk",
452 "Como eu posso te ajudar?",
453 "Quanto custa as camisas nesse estilo?",
454 "Quer agendar uam visita para experimentar e dá uma
↪ olhadinha no nosso catálogo?",
455 "Que bom",
456 "Você tem sete dias para realizar a troca caso ela não
↪ goste",
457 "Quais peças de roupa você tem interesse?",
458 "Você tem acompanhado nossa coleção?",
459 "Vamos garantir seu vestido?",
460 "Tem tamanho maior?",
461 "Podemos trocar se quiser",
462 "Bom dia e desculpa a demora, quais peças são do seu
↪ interesse?",
463 "Tamanho 38?",
464 "Olá não se interessou pelo preto?",
465 "Boa tarde perdão pela demora, quais peças te
↪ interessou?",
466 "Bom dia, o que achou?",
467 "Seria um 42?",

468 "Qual tamanho você usa?",
469 "Tem interesse no vestido ainda?",
470 "Tem interesse nas blusinhas?",
471 "Boa noite vamos garantir o seu vestido?",
472 "Qual estilo de vestidos você gosta?",
473 "Quais os vestidos em oferta hoje?",
474 "Você possui algum conjunto azul manho? Tenho interesse",
475 "Tenho interesse em vestido, quais você tem?",
476 "Qual o seu catálogo?",
477 "Qual o tamanho desse vestido 3 laranja?",
478 "Você tem um short 36?",
479 "Quais saias você possui?",
480 "Ele tem bojo?",
481 "O que achou da saia?",
482 "Vocês vendem lingerie?",
483 "Quanto está o conjunto da foto?",
484 "O vestido ainda está disponível?",
485 "Você tem o modelo da blusa baby look?",
486 "A blusa ficou apertada você tem tamanho maior? Gosto
↪ quando fica soltinha no corpo",
487 "Tem como enviar as fotos dos modelos 42?",
488 "Tem no 44 também?",
489 "Tem bermudas?",
490 "Tem muita coisa nova?",
491 "Você tem cropped disponível?",
492 "Boa tarde quais saias estão disponíveis?",
493 "Quais as cores daquela blusa?",
494 "Quais as cores, tamanhos e valor?",
495 "Qual a cor?",
496 "Oi qual o tamanho?",
497 "Bom dia você ainda tem esse vestido?",
498 "Você tem conjunto?",
499 "Você ainda tem nesse modelo?",
500 "Você tem saia babado?",
501 "Olá bom dia vocês tem vestido envelope?",
502 "Você trabalha com roupas masculinas?",
503 "Vai ser quanto?",
504 "Qual a forma de pagamento?",
505 "Por favor quanto custa esse conjunto?",

```
506         "Qual forma de pagamento?",
507         "Qual o valor?",
508         "Boa noite eu amei a saia qual o valor?",
509         "Amei esse conjunto, quanto custa?",
510         "qual tamanho?",
511         "Qual a cor?",
512         "Você recebeu as peças?",
513         "Qual o seu endereço de entrega?"
514     ]
515 },
516 {
517     "tag": "CONFIRMAR",
518     "patterns": [
519         "Certo.",
520         "Pode ser",
521         "Sim, obrigada",
522         "Só isso mesmo, obrigada",
523         "Caramba, por esse preço não tem como eu dizer não. Vou
524         ↪ levar",
525         "Ok, obrigado e boa tarde",
526         "Ah, camisa temos",
527         "Sim, também acho rsrs",
528         "Certo, vou processar o pedido.",
529         "Tá certo",
530         "sim, tá ótimo",
531         "está bem",
532         "Pode ser",
533         "quero",
534         "demoro",
535         "To vendo aqui parece daora vo querer",
536         "bele sugere ai",
537         "ve esse ai tambem",
538         "Sim, está disponível.",
539         "pronto, vou querer jeans, chiquerrima demais",
540         "é o desemprego, moça, brasil tá tenso T^T",
541         "Ok. Vou ficar com a P",
542         "Sim. Descontos de até 20% em compras acima de 200
543         ↪ reais.",
544         "ai sim, vou querer!!!",
```

```
543         "ai sim, bom demais, me vê 1 vestido de cada agr",
544         "Tenho! Qual tamanho você quer?",
545         "Então ta bom, ta aqui a sua blusa!",
546         "Ta bom.. Então combinado 12x sem juros!",
547         "Sim. Quero uma slim",
548         "Sim. Na cor preta, por gentileza.",
549         "tudo bem",
550         "Ok, obrigado.",
551         "Tudo confirmado. Boa tarde e obrigado pela
552         ↪ preferência.",
553         "Sim. A estampada.",
554         "Claro pode deixar",
555         "Já vou encomendar",
556         "Tá bem",
557         "São perfeitas",
558         "Obrigada",
559         "Ok Obrigada",
560         "Já quero",
561         "Lindo",
562         "Bom dia tenho sim",
563         "Gostei desse",
564         "ok",
565         "Isso é ótimo, obrigada",
566         "Amei",
567         "Adorei essas peças",
568         "ok",
569         "Bem melhor esse",
570         "Bem melhor",
571         "Tenho acompanhado por aqui e no instagram",
572         "A calça sim",
573         "A calça coube",
574         "Tá bom",
575         "Sim",
576         "Temos sim"
577     ],
578     {
579         "tag": "NEGAR",
580         "patterns": [
```

```

581         "Ah, mas não vai combinar com a minha blusa",
582         "Não obrigado, só os moletos por enquanto",
583         "Mas você ainda não disse o tamanho do moletom, moço,
        ↪ vamos com calma.",
584         "Ah essa cor não tem não",
585         "Não, mas acredite, ela vai amar essa saia de cintura
        ↪ alta",
586         "Hm... Não sei...",
587         "Não, só isso mesmo",
588         "É lindo mesmo, mas vai ficar pra próxima",
589         "também não temos, os P estão em falta",
590         "Infelizmente, não temos saias :')",
591         "Não, ta fazendo calor",
592         "Nenhuma das duas. Obrigado.",
593         "nao",
594         "Infelizmente está indisponível.",
595         "Lamento ):",
596         "quero não, moça, tô com pouco dinheiro",
597         "ai moça, que facada",
598         "vou querer não, é muito dinheiro pra gastar",
599         "ah não não, é demais pra mim, tô com pouca bufunfa agr",
600         "Não temos tamanho P no momento. Tem interesse em algum
        ↪ outro tamanho?",
601         "Não",
602         "Não, só isso mesmo. Obrigado, bom dia.",
603         "Não temos no momento calça. Gostaria de ver as saias ou
        ↪ vestidos??",
604         "Não vai dá para pegar hoje",
605         "Não precisa trocar obrigada",
606         "Tá achando que não vai caber nela o 42",
607         "Não"
608     ]
609 },
610 {
611     "tag": "SOLICITAR",
612     "patterns": [
613         "Gostaria de um modelo com manga longa, gola em V de
        ↪ tamanho PP",
614         "me informe o seu endereço para envio",

```

```
615         "Ve uma calça G jeans zebra slim intermediaria",
616         "vou querer uma blusa coura, vê se tem, moça hehe",
617         "ah moço, quero que mande pra cá, com essa pandemia,
        ↳ quero nem sair de casa kkkkkkk",
618         "3 vez só??? mas moço, coloque 12x sem juros",
619         "Boa noite. Quero uma blusa",
620         "Me manda o link dessas peças",
621         "Manda foto das calças",
622         "Avisse por favor. Adoro a cor azul. E essas estão
        ↳ lindas",
623         "Eu quero uma de olho grego E uma dessa alma colorida",
624         "Me passa o endereço",
625         "Vamos agendar um horário",
626         "Dá uma olhada nesse link",
627         "Me manda o link para eu passar o cartão",
628         "me envia o comprovante de pagamento",
629         "Me manda o catálogo",
630         "Me envie fotos do catálogo",
631         "Me envie o link de pagamento",
632         "Manda o link do top",
633         "Boa noite me manda as medidas direitinho",
634         "Entendi, você realiza a troca?",
635         "Boa noite, sua amiga gostou?",
636         "Foto dos short saias",
637         "Manda foto das roupas",
638         "Tem tamanho 40?",
639         "Você já viu os crooped que chegaram daquele modelo que
        ↳ você gostou?",
640         "Manda as fotos para eu ver os modelos",
641         "Reserva para mim esse macacão"
642     ]
643 }
644 ]
645 }
```

Referências bibliográficas

- Talk to transformer, 2019. URL <https://talktotransformer.com/>. Online; acessado 02 Junho 2020.
- aza, muha, zura, and Nahdatul Akma Ahmad. Review of chatbots design techniques. *International Journal of Computer Applications*, 181:7–10, 08 2018.
- Daniel-F. Casati F. Benatallah B. Baez, M. Chatbot integration in few patterns. *IEEE Internet Computing*, 25:52 – 59, 9 2020. DOI [10.1109/MIC.2020.3024605](https://doi.org/10.1109/MIC.2020.3024605).
- Jordan Bird, Aniko Ekart, and Diego Faria. *Learning from Interaction: An Intelligent Networked-Based Human-Bot and Bot-Bot Chatbot System: Contributions Presented at the 18th UK Workshop on Computational Intelligence, September 5-7, 2018, Nottingham, UK*, pages 179–190. 01 2019. ISBN 978-3-319-97981-6. DOI [10.1007/978-3-319-97982-3_15](https://doi.org/10.1007/978-3-319-97982-3_15).
- Tom Bocklisch, Joey Faulkner, Nick Pawlowski, and Alan Nichol. Rasa: Open source language understanding and dialogue management, 2017. URL <https://arxiv.org/abs/1712.05181>.
- Ministério da Cidadania Brasil. Lei geral de proteção de dados pessoais, 2018. URL <https://www.gov.br/cidadania/pt-br/acesso-a-informacao/lgpd>. Online; acessado 03 Janeiro 2023.
- Rollo Carpenter and Dr Jonathan Freeman. Computing machinery and the individual: the personal turing test, 2005. URL <http://www.jabberwacky.com/personaltt>. Online; acessado 18 Maio 2020.
- Sunil Kumar Chinnamgari. *R Machine Learning Projects: Implement supervised, unsupervised, and reinforcement learning techniques using R 3.5*. Packt Publishing Ltd, 2019.
- Minjee Chung, Eunju Ko, Heerim Joung, and Sang Kim. Chatbot e-service and customer satisfaction regarding luxury brands. *Journal of Business Research*, 11 2018. DOI [10.1016/j.jbusres.2018.10.004](https://doi.org/10.1016/j.jbusres.2018.10.004).

- Nello Cristianini and John Shawe-Taylor. *An Introduction to Support Vector Machines and Other Kernel-based Learning Methods*. Cambridge University Press, 2000.
DOI [10.1017/CBO9780511801389](https://doi.org/10.1017/CBO9780511801389).
- Cristian Danescu-Niculescu-Mizil and Lillian Lee. Chameleons in imagined conversations: A new approach to understanding coordination of linguistic style in dialogs. In *Proceedings of the Workshop on Cognitive Modeling and Computational Linguistics, ACL 2011*, 2011.
- Andrea De Mauro, Marco Greco, and Michele Grimaldi. What is big data? a consensual definition and a review of key research topics. 09 2014. **DOI** [10.13140/2.1.2341.5048](https://doi.org/10.13140/2.1.2341.5048).
- Jacob Devlin, Ming-Wei Chang, Kenton Lee, and Kristina Toutanova. Bert: Pre-training of deep bidirectional transformers for language understanding, 2018.
URL <https://arxiv.org/abs/1810.04805>.
- Boris Galitsky. *Chatbot Components and Architectures*, pages 13–51. Springer International Publishing, Cham, 2019. ISBN 978-3-030-04299-8.
DOI [10.1007/978-3-030-04299-8_2](https://doi.org/10.1007/978-3-030-04299-8_2). URL https://doi.org/10.1007/978-3-030-04299-8_2.
- Ian Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair, Aaron Courville, and Yoshua Bengio. Generative adversarial nets. In Z. Ghahramani, M. Welling, C. Cortes, N. Lawrence, and K.Q. Weinberger, editors, *Advances in Neural Information Processing Systems*, volume 27. Curran Associates, Inc., 2014. URL <https://proceedings.neurips.cc/paper/2014/file/5ca3e9b122f61f8f06494c97b1afccf3-Paper.pdf>.
- Google. Google cloud products, 03 2018. URL <https://cloud.google.com>. Online; acessado 01 Junho 2020.
- Palash Goyal, Sumit Pandey, and Karan Jain. *Deep Learning for Natural Language Processing*. Apress, 1 edition, 06 2018. ISBN 978-1-4842-3685-7.
DOI [10.1007/978-1-4842-3685-7](https://doi.org/10.1007/978-1-4842-3685-7).
- Alex Graves and Jürgen Schmidhuber. Framewise phoneme classification with bidirectional lstm and other neural network architectures. *Neural networks : the official journal of the International Neural Network Society*, 18 5-6:602–10, 2005.
- Sepp Hochreiter and Jürgen Schmidhuber. Long short-term memory. *Neural computation*, 9:1735–80, 12 1997. **DOI** [10.1162/neco.1997.9.8.1735](https://doi.org/10.1162/neco.1997.9.8.1735).

- Patrik Hrkút, Štefan Toth, Michal Ďuračík, Matej Meško, Emil Krsak, and Miroslava Mikušová. *Data Collection for Natural Language Processing Systems*, pages 60–70. 03 2020. ISBN 978-981-15-3379-2. DOI [10.1007/978-981-15-3380-8_6](https://doi.org/10.1007/978-981-15-3380-8_6).
- Invesp. Chatbots in customer service – statistics and trends, 2019. URL <https://www.invespcro.com/blog/chatbots-customer-service/>. Online; acessado 05 Janeiro 2023.
- Charles Lee Isbell, Michael Kearns, Satinder Singh, Peter Stone, and Dave Kormann. Cobot in lambdamoo: A social statistics agent. *American Association for Artificial Intelligence*, pages 36–41, 2000.
- Sheenam Jain, J Bruniaux, Xianyi Zeng, and Pascal Bruniaux. Big data in fashion industry. *IOP Conference Series: Materials Science and Engineering*, 254:152005, 10 2017. DOI [10.1088/1757-899X/254/15/152005](https://doi.org/10.1088/1757-899X/254/15/152005).
- Seong-Soo Jeong and Yeong-Seok Seo. Improving response capability of chatbot using twitter. *Journal of Ambient Intelligence and Humanized Computing*, 02 2019. DOI [10.1007/s12652-019-01347-6](https://doi.org/10.1007/s12652-019-01347-6).
- Dan Jurafsky and James H. Martin. *Speech and Language Processing*. 3 edition, 10 2019. URL <https://web.stanford.edu/~jurafsky/slp3/>.
- R. Khan and A. Das. *Build Better Chatbots*. Apress, 1 edition, 2017. ISBN 9781484231111. DOI [10.1007/978-1-4842-3111-1](https://doi.org/10.1007/978-1-4842-3111-1).
- Rashid Khan and Anik Das. *Introduction to Chatbots*, pages 1–11. Apress, Berkeley, CA, 2018. ISBN 978-1-4842-3111-1. DOI [10.1007/978-1-4842-3111-1_1](https://doi.org/10.1007/978-1-4842-3111-1_1). URL https://doi.org/10.1007/978-1-4842-3111-1_1.
- Olaf Kopp. How google uses nlp to better understand search queries, content, 2022. URL <https://searchengineland.com/how-google-uses-nlp-to-better-understand-search-queries-content-387340>. Online; acessado 03 Janeiro 2023.
- Satwik Kottur, Seungwhan Moon, Alborz Geramifard, and Babak Damavandi. Simmc 2.0: A task-oriented dialog dataset for immersive multimodal conversations, 2021. URL <https://arxiv.org/abs/2104.08667>.
- Karolina Kuligowska. Commercial chatbot: Performance evaluation, usability metrics and quality standards of embodied conversational agents. *Professionals Center for Business Research*, 2:1–16, 01 2015. DOI [10.18483/PCBR.22](https://doi.org/10.18483/PCBR.22).

- Abbas Lokman and Mohamed Ameen. *Modern Chatbot Systems: A Technical Review*, pages 1012–1023. 01 2019. ISBN 978-3-030-02682-0.
DOI [10.1007/978-3-030-02683-7_75](https://doi.org/10.1007/978-3-030-02683-7_75).
- Edward Loper and Steven Bird. Nltk: The natural language toolkit, 2002. URL <https://arxiv.org/abs/cs/0205028>.
- Edward Ma. Nlp augmentation. <https://github.com/makcedward/nlpaug>, 2019.
- Julia Masche and Nguyen-Thinh Le. A review of technologies for conversational systems. In Nguyen-Thinh Le, Tien van Do, Ngoc Thanh Nguyen, and Hoai An Le Thi, editors, *Advanced Computational Methods for Knowledge Engineering*, pages 212–225, Cham, 2018. Springer International Publishing. ISBN 978-3-319-61911-8.
DOI [10.1007/978-3-319-61911-8_9](https://doi.org/10.1007/978-3-319-61911-8_9).
- Michael F. McTear. *Spoken Dialogue Technology - Toward the Conversational User Interface*. Springer, London, 01 2004. ISBN 978-1-85233-672-1.
- Microsoft. Tay, 03 2016. URL <https://twitter.com/tayandyou>. Online; acessado 10 Junho 2020.
- Tomas Mikolov, Kai Chen, Greg Corrado, and Jeffrey Dean. Efficient estimation of word representations in vector space, 2013. URL <https://arxiv.org/abs/1301.3781>.
- Seungwhan Moon, Satwik Kottur, Paul A. Crook, Ankita De, Shivani Poddar, Theodore Levin, David Whitney, Daniel Difrancio, Ahmad Beirami, Eunjoon Cho, Rajen Subba, and Alborz Geramifard. Situated and interactive multimodal conversations, 2020. URL <https://arxiv.org/abs/2006.01460>.
- Shcherbakov M. Nguyen, T. Enhancing rasa nlu model for vietnamese chatbot. *International Journal of Open Information Technologies*, 9(1):31 – 36, 2021.
- Outgrow. 50+ vital chatbot statistics for 2021, 2021. URL <https://outgrow.co/blog/vital-chatbot-statistics>. Online; acessado 05 Janeiro 2023.
- Rodrigo Pimentel. Chatito, 2018. URL <https://rodrigopivi.github.io/Chatito/>. Online; acessado 02 Junho 2020.
- Alec Radford, Jeffrey Wu, Rewon Child, David Luan, Dario Amodei, and Ilya Sutskever. Language models are unsupervised multitask learners. 2019.
- Seref Sagiroglu and Duygu Sinanc. Big data: A review. In *2013 International Conference on Collaboration Technologies and Systems (CTS)*, pages 42–47, 2013.
DOI [10.1109/CTS.2013.6567202](https://doi.org/10.1109/CTS.2013.6567202).

- Jetze Schuurmans and Flavius Frasincar. Intent classification for dialogue utterances. *IEEE Intelligent Systems*, 35(1):82–88, 2020. DOI [10.1109/MIS.2019.2954966](https://doi.org/10.1109/MIS.2019.2954966).
- Iulian Serban, Chinnadhurai Sankar, Mathieu Germain, Saizheng Zhang, Zhouhan Lin, Sandeep Subramanian, Taesup Kim, Michael Pieper, Sarath Chandar, Nan Ke, Sai Mudumba, Alexandre Brebisson, Jose Sotelo, Dendi Suhubdy, Vincent Michalski, Alexandre Nguyen, Joelle Pineau, and Y. Bengio. A deep reinforcement learning chatbot. 09 2017.
- Iulian Vlad Serban, Ryan Lowe, Peter Henderson, Laurent Charlin, and Joelle Pineau. A survey of available corpora for building data-driven dialogue systems. 9(1):1–49, 2018. DOI [10.5087/dad.2018.101](https://doi.org/10.5087/dad.2018.101).
- Serviço Federal de Processamento de Dados SERPRO. O que são dados anonimizados, segundo a lgpd, 2022. URL <https://www.serpro.gov.br/lgpd/menu/protecao-de-dados/dados-anonimizados-lgpd>. Online; acessado 03 Janeiro 2023.
- M. A. Turing. Computing machinery and intelligence. *Mind*, 59:433–460, 1950.
- M. Wallace. Eliza, the rogerian therapist, 1999. URL <http://psych.fullerton.edu/mbirnbaum/psych101/Eliza.htm>.
- Joseph Weizenbaum. Eliza - a computer program for the study of natural language communication between man and machine. *Communications of the ACM*, 9(1):36–45, 01 1966. DOI [10.1145/365153.365168](https://doi.org/10.1145/365153.365168).
- Anbang Xu, Zhe Liu, Yufan Guo, Vibha Sinha, and Rama Akkiraju. A new chatbot for customer service on social media. 05 2017. DOI [10.1145/3025453.3025496](https://doi.org/10.1145/3025453.3025496).
- Jianfei Yu, Minghui Qiu, Jing Jiang, Jun Huang, Shuangyong Song, Wei Chu, and Haiqing Chen. Modelling domain relationships for transfer learning on retrieval-based question answering systems in e-commerce. *CoRR*, abs/1711.08726, 2017. URL <http://arxiv.org/abs/1711.08726>.
- Yong Yu, Xiaosheng Si, Changhua Hu, and Jianxun Zhang. A review of recurrent neural networks: Lstm cells and network architectures. *Neural Computation*, 31(7):1235–1270, 2019. DOI [10.1162/neco_a01199](https://doi.org/10.1162/neco_a01199).
- Yian Zhang, Alex Warstadt, Haau-Sing Li, and Samuel R. Bowman. When do you need billions of words of pretraining data?, 2020. URL <https://arxiv.org/abs/2011.04946>.