

UNIVERSIDADE DE SÃO PAULO  
FACULDADE DE FILOSOFIA, CIÊNCIAS E LETRAS DE RIBEIRÃO PRETO  
DEPARTAMENTO DE COMPUTAÇÃO E MATEMÁTICA

LUCAS PIMENTA PORTO

**Pós-processamento de textos de tradução automática  
baseado em teoria de grafos**

Versão Corrigida

Ribeirão Preto-SP

2020

Lucas Pimenta Porto

Pós-processamento de textos de tradução automática baseado em teoria de grafos.  
Ribeirão Preto–SP, 2020.

97p. : il.; 30 cm.

Dissertação apresentada à Faculdade de Filosofia, Ciências e Letras  
de Ribeirão Preto da USP, como parte das exigências para  
a obtenção do título de Mestre em Ciências,  
Área: Computação Aplicada.

Orientador: Evandro Eduardo Seron Ruiz

1. Coerência textual. 2. Tradução automática. 3. Teoria dos grafos.

Lucas Pimenta Porto

Pós-processamento de textos de tradução automática baseado em teoria de grafos

Modelo canônico de trabalho monográfico acadêmico em conformidade com as normas ABNT.

Trabalho aprovado. Ribeirão Preto–SP, 06 de janeiro de 2021:

---

**Orientador:**

Membro da Banca: Evandro Eduardo Seron  
Ruiz

---

**Professor**

Membro da Banca: Evandro Marcos Saidel  
Ribeiro

---

**Professor**

Membro da Banca: Ariani Di Felippo

Ribeirão Preto–SP

2020

*Esse trabalho é dedicado a todos os cientistas da computação  
que são amantes da língua portuguesa.*

# Agradecimentos

Eternamente agradecido aos meus pais José Luiz Porto e Maria Marta P. Porto, pelo amor, investimento, carinho, incentivo e amizade que sempre me proporcionaram. Eles são um modelo para minha vida, pessoas realmente admiráveis pelas quais agradeço a Deus.

Sou grato também a Fernanda Gabler, minha eterna namorada e futura esposa. Alguém por quem sou completamente apaixonado e que, ao longo desse projeto, sempre foi compreensiva, incentivadora, auxiliadora e amiga. Me impressionando positivamente em inúmeros detalhes, mesmo nos momentos mais difíceis.

Agradeço ao professor Evandro Eduardo Seron Ruiz, a quem tive o privilégio de conhecer. Um grande incentivador e orientador, alguém que admiro e que considero como amigo. Uma pessoa que me inspirou e me ensinou a como ser um professor, sempre com um toque sutil e eficaz.

Meus agradecimentos vão também para as pessoas com quem trabalho ou trabalhei como professor Carlos Onofre, Patrícia, José Maia, Helena, professores Rogério e Guilherme Henrique. Obrigado pela ajuda, amizade e entusiasmo.

E por último e mais importante eu agradeço a Deus que, sempre esteve comigo, Me guiando e colocando diante de mim pessoas e oportunidades maravilhosas. Sempre me proporcionando o privilégio de estudar nessa instituição renomada de ensino onde tenho sido constantemente desafiado a me aprimorar como futuro cientista e professor. Muito obrigado, Senhor.

*"O que foi tornará a ser,  
o que foi feito se fará novamente;  
não há nada novo debaixo do sol."  
(Bíblia Sagrada, Eclesiastes 1, 9)*

# Resumo

A tradução automática está intrinsecamente associada ao estudo e desenvolvimento de metodologias computadorizadas para a produção de traduções idiomáticas. As abordagens mais utilizadas são as abordagens estatísticas e as abordagens baseadas em redes neurais. Uma das deficiências apontadas por estes métodos é a possível falta de coerência entre as sentenças traduzidas. Neste projeto propomos a utilização de técnicas baseadas na Teoria de Grafos para conservar a coerência na tradução dos textos do Inglês para o Português. O método estudado apresenta grande variabilidade de desempenho, no entanto, algumas traduções apresentam resultados 90% melhores do que o tradutor estatístico Moses e 10% superior ao Google Tradutor.

**Palavras-chave:** coerência textual. tradução automática. teoria dos grafos.

# Abstract

Machine translation is intrinsically associated with the study and development of computerized methodologies for idiomatic translations' production. The most common approaches are the statistical and methods based on neural networks. One of the deficiencies pointed out by these methods is the possible lack of coherence between the translated sentences. In this project, we propose using techniques based on Graph Theory to preserve the coherence in the translation of texts from English to Portuguese. The studied method presents large performance variability; however, some translations produce sentences 90% better evaluated than the statistical translator Moses and 10% superior to Google Translate.

**Keywords:** textual coherence. automatic translation. graph theory.



# Lista de figuras

Figura 1 – Grafo de Entidades gerado mediante o texto apresentado na Tabela 2. .	24
Figura 2 – Neste exemplo temos um Grafo de Projeção elaborado a partir do conceito do Grafo de Entidades mostrado na Figura 1, página 24. Nele, vemos as sentenças do texto da Tabela 2 (pág. 23) representadas por vértices e a relação semântica entre elas por arestas direcionais. ....	25
Figura 3 – A esquerda vemos um grafo de relações discursivas (RD) não ponderado e a direita temos o mesmo grafo RD com pesos em suas arestas. Ambos construídos a partir do corpus Penn Speech Treebank. Observação: esse exemplo foi construído e não tem qualquer relação com o texto apresentado na Tabela 2 (pág. 23). ....	26
Figura 4 – Exemplo de Subgrafos de 3 nós com suas respectivas identificações, citado na subseção 1.12 (página 27). ....	28
Figura 5 – Exemplo de Subgrafos de 4 nós com suas respectivas identificações, citado na subseção 1.12 (página 27). ....	28
Figura 6 – Exemplo de Subgrafos de 5 nós com suas respectivas identificações, citado na subseção 1.12 (página 27). ....	29
Figura 7 – Esquematização do funcionamento da máquina de tradução Moses.....	34
Figura 8 – Exemplo simples do processo de tradução automático baseado em frases.	36
Figura 9 – Tabela de alinhamento de palavras entre duas sentenças, do inglês para o português do português para o inglês e a união das tabelas. ....	37
Figura 10 – Exemplo simples de como funciona o algoritmo <i>beam search</i> com três etapas de busca, onde em cada uma delas os dois melhores resultados são selecionados. ....	38
Figura 11 – Funcionamento básico do algoritmo <i>beam search</i> no decodificador Moses durante a construção tradutória da sentença “ <i>Louise loves Peter</i> ” .....	40
Figura 12 – Exemplo simples de pilhas conforme o tamanho das frases. ....	41
Figura 13 – Recombinação de duas hipóteses (frases) que cobrem duas palavras. ....	42
Figura 14 – A pilha em destaque armazena apenas frases que cobrem toda a sentença.	43
Figura 15 – Exemplo de Lista N-Best com relação as três melhores traduções das sentenças apresentadas na Tabela 5 pág. 44.....	45
Figura 16 – Fluxograma básico do funcionamento do nosso projeto.....	48
Figura 17 – Desmonstrativo de como identificamos as classes gramaticais das palavras em uma sentença com biblioteca spaCy .....	48
Figura 18 – Comparando, por meio da nossa técnica de grafos, palavras de mesma classe gramatical e que pertencem a opções de tradução vinculadas a sentenças distintas. ....	49

Figura 19 – Exemplo de pontuação referente as opções de tradução ilustradas na Figura 18 (pág.49).....	49
Figura 20 – Exemplo de quando as opções de tradução empatam na pontuação.....	50
Figura 21 – Separando as opções de tradução e as palavras que as compõem mediante as sentenças que elas representam. ....	51
Figura 22 – Exemplo de transferência das opções de tradução para uma Lista.....	51
Figura 23 – Transferindo as opções de tradução e suas respectivas palavras de uma Lista para um Dicionário.....	52
Figura 24 – Reconhecendo sentenças, opções de tradução e palavras por meio de um dicionário.....	53
Figura 25 – Grafo construído apenas por meio de substantivos (referente ao texto na Tabela 7, página 54).....	55
Figura 26 – Grafo construído apenas por meio de adjetivos (referente ao texto na Tabela 7, página 54.....	55
Figura 27 – Grafo construído apenas por meio de substantivos (referente ao texto na Tabela 7, página 54).....	56
Figura 28 – Grafo construído apenas por meio de adjetivos (referente ao texto na Tabela 7, página 54.....	56
Figura 29 – Construção de nossa lista NBest nessa terceira etapa a partir das três melhores traduções de um mesmo texto classificadas pelas métricas Meteor e BLEU nos experimentos anteriores. Em azul, cinza e laranja, mostramos as três melhores traduções com as quais criamos nossa lista NBest que está ilustrada na cor roxa. Em amarelo, destacamos apenas a sentença 1 para exemplificar o processo de elaboração da nossa lista.	68
Figura 30 – Nessa ilustração, temos a identificação de cada opção de tradução do resumo 01 seguidas por suas respectivas pontuações alcançadas mediante nossa técnica de grafos.....	72
Figura 31 – Grafo correspondente as interações semânticas entre as opções de tradução, pertencentes a sentenças diferentes referente ao que foi ilustrado nas Figuras 30 (pág. 72) e 32 (pág. 73).....	72
Figura 32 – A partir do que foi mostrado na Figura 30 (pág. 72) nós exemplificamos aqui a última etapa da construção da tradução do resumo 01 segundo nossa técnica. Destacamos duas opções de tradução que, de acordo com o Moses, não seriam as melhores traduções para suas respectivas sentenças mas que, segundo nossa técnica, foram consideradas melhores conforme a pontuação que elas obtiveram.....	73
Figura 33 – Pontuação das opções de tradução referentes ao resumo 15, emitidas no Experimento 3 segundo nossa técnica de grafos.....	74

Figura 34 – Comparando a melhor tradução emitida nas etapas 5.2.1 e 5.2.2 do resumo 15, com a tradução do mesmo texto gerada no Experimento 3.	75
Figura 35 – Grafo referente a tradução emitida pela nossa técnica no Experimento 3 com relação ao resumo 15.....	76
Figura 36 – Pontuação das opções de tradução referentes ao resumo 36, obtidas nesse Experimento 3.....	76
Figura 37 – Comparando a melhor tradução emitida nas etapas 1 (pág. 70) e 2 (pág. 71), referente ao resumo 36 com a tradução do mesmo texto gerada no experimento 3. ....	77
Figura 38 – Grafo referente a tradução emitida pela nossa técnica com relação ao resumo 36 no Experimento 3.....	78
Figura 39 – Comparando a tradução do resumo 36 obtido no Experimento 3, com a gerada pelo Google Tradutor e a tradução de referencia elaborada por um humano. Nossa tradução (experimento 3) superou em 8% a tradução do Google segundo a métrica Meteor. ....	79
Figura 40 – Pontuações das opções de tradução conforme a lista NBest que criamos no Experimento 3, referente ao resumo 36. ....	80
Figura 41 – Grafo referente a tradução do resumo 36 alcançado no Experimento 3 e exposto na Figura 39 (pág. 79). ....	80
Figura 42 – Comparando a tradução do resumo 27 obtido no Experimento 3, com a gerada pelo Google Tradutor e a tradução de referencia elaborada por um humano. Nossa tradução (experimento 3) superou em 4% a tradução do Google segundo a métrica BLEU.....	81
Figura 43 – Pontuações da Opções de tradução conforme a lista NBest que criamos no Experimento 3 referente ao resumo 27. ....	81
Figura 44 – Grafo referente a tradução do resumo 27 alcançado no Experimento 3 e exposto na Figura 42 (pág. 81). ....	82

## **Lista de tabelas**

Tabela 1 – comparação.....	20
Tabela 2 – Pequeno texto com 9 sentenças e seus respectivos substantivos identificados em colchetes.....	23
Tabela 3 – Comparativo entre a máquina de tradução Moses com outros dois decodificadores estatísticas baseadas em frases.....	35
Tabela 4 – Nessa tabela temos as palavras da sentença em inglês, mostrada anteriormente e as respectivas possíveis traduções (opções) para cada uma delas.....	39

Tabela 5 – Apresetamos três sentenças em inglês as quais submetemos ao Moses para obtermos um exemplo de lista NBest com as três melhores traduções de cada uma dessas sentenças. ....	44
Tabela 6 – Pequeno texto em Inglês composto por 4 sentenças. ....	54
Tabela 7 – Lista NBest com 3 opções de tradução por sentença. Referente ao texto na Tabela 6, página 54 .....	54
Tabela 8 – Comparando a tradução produzida pelo nosso modelo com a emitida pelo Moses. Podemos perceber que, para a terceira sentença, nosso modelo selecionou um opção de tradução diferente da que o Moses escolheu.....	57
Tabela 9 – Relação dos Corpus Paralelos que nós utilizamos no Treinamento da nossa Máquina de Tradução. Nessa tabela, temos os nomes de cada corporea, o número de linhas de compõe cada um deles e a quantidade de palavras (tokens) em inglês e português presentes em sua composição. ....	61
Tabela 10 – Na primeira coluna temos os nomes de cada arquivo moses.ini. Em seguida, apresentamos os corpus utilizados na elaboração do modelo de tradução (MT) e modelo de linguagem (ML). Na sequencia, mostramos os corpus empregados na calibragem (tunnig) da relação entre MT e ML durante o processo tradutório. Por fim, apresentarmos as corporeas avaliativas, utilizadas para qualificar as traduções conforme os arquivos moses.ini. ....	64
Tabela 11 – Relação de Textos utilizados em nossos testes. ....	66
Tabela 12 – Aqui expomos os três arquivos moses.ini que criamos para essa etapa de testes. Nessa tabela, também referenciamos os corpus utilizados na construção de cada Modelo de Tradução (MT). Além disso, mostramos o Modelo de Linguagem (ML) criado por nós e evocado pelos três moses.ini. ....	67
Tabela 13 – Resultado Experimento 1 - SEM a TÉCNICA DE GRAFOS - conforme a métrica METEOR. Em vermelho, as traduções que se saíram melhores com as registradas na Tabela 14.....	84
Tabela 14 – Resultado Experimento 1 - COM a TÉCNICA DE GRAFOS - conforme a métrica METEOR. Em vermelho, as traduções que se saíram melhores com as registradas na Tabela 13.....	85
Tabela 15 – Resultado Experimento 1 - SEM a TÉCNICA DE GRAFOS - conforme a métrica BLEU. Em vermelho, as traduções que se saíram melhores com as registradas na Tabela 16.....	86
Tabela 16 – Resultado Experimento 1 - COM a TÉCNICA DE GRAFOS - conforme a métrica BLEU. Em vermelho, as traduções que se saíram melhores com as registradas na Tabela 15.....	87

Tabela 17 – Experimento 2 - Resultados obtidos pela métrica Meteor. Em vermelho, as traduções que se saíram melhores comparado a suas concorrentes. .	88
Tabela 18 – Experimento 2 - Resultados obtidos pela métrica BLEU. Em vermelho, as traduções que se saíram melhores comparado a suas concorrentes. .	89
Tabela 19 – Resultados alcançados nos experimentos 3 e 4. Considere Exp.3 como experimento 3. ....	90

# Sumário

	Introdução .....	15
1	REFERENCIAL TEÓRICO.....	17
1.1	Tradução Automática.....	17
1.2	Máquina de Tradução Estatística .....	18
1.3	Máquina de Tradução Neural.....	18
1.4	SMT vs. NMT.....	19
1.5	Problemas com Ambas as Máquinas de Tradução.....	19
1.6	Coerência Textual .....	20
1.7	Modelando Computacionalmente a Coerência Textual.....	21
1.8	Grafos de Entidade.....	22
1.9	Grafo de Projeção .....	24
1.10	Grafos de Relações Discursivas.....	24
1.11	Coerência Textual na Tradução Automática .....	26
1.12	Um Modelo de Coerência Baseado em Grafos para a Tradução Automática .....	27
1.13	Resumo do Capítulo.....	30
2	OBJETIVOS.....	31
2.1	Objetivo principal.....	31
2.2	Objetivos secundários.....	31
3	METODOLOGIA .....	33
3.1	Moses .....	33
3.2	O que nos levou a optar pelo Moses .....	35
3.3	Modelo Baseado em Frases .....	35
3.3.1	Conceito de Frases na Tradução Automática.....	35
3.3.2	Alinhamento de palavras.....	36
3.3.3	<i>Beam Search</i> – Pesquisa por Feixe.....	37
3.3.4	<i>Beam Search</i> Baseado em Pilhas no Decodificador Moses .....	39
3.4	Lista NBest.....	44
3.5	O que nos levou a optar pela Lista NBest .....	44
3.6	Como utilizamos a lista NBest.....	45
3.7	Inovação.....	46
3.8	Construindo nosso modelo de coerência baseado em grafos.....	47
3.8.1	Utilizando as Estruturas de Dados.....	50

# SUMÁRIO

14

<b>3.9</b>	<b>Avaliando os Resultados.....</b>	<b>57</b>
3.9.1	BLEU .....	57
3.9.2	Meteor .....	58
<b>3.10</b>	<b>Resumo do Capitulo .....</b>	<b>58</b>
<b>4</b>	<b>EXPERIMENTOS .....</b>	<b>59</b>
<b>4.1</b>	<b>Configurações do Equipamento .....</b>	<b>59</b>
<b>4.2</b>	<b>Corpora de Treinamento para a Máquina de Tradução .....</b>	<b>60</b>
<b>4.3</b>	<b>Treinando a Máquina de Tradução Moses .....</b>	<b>61</b>
<b>4.4</b>	<b>O que Utilizamos para construir nosso Modelo de Coerência.....</b>	<b>62</b>
<b>4.5</b>	<b>Utilizando o Moses em Nosso Experimento.....</b>	<b>63</b>
4.5.1	Como Servidor .....	63
4.5.2	Arquivo Moses.ini .....	63
<b>4.6</b>	<b>Experimentos.....</b>	<b>64</b>
4.6.1	Corpus de testes .....	64
4.6.2	Experimento 1 .....	65
4.6.3	Experimento 2 .....	65
4.6.4	Experimento 3 .....	67
4.6.5	Experimento 4 .....	67
<b>4.7</b>	<b>Resumo do Capitulo .....</b>	<b>68</b>
<b>5</b>	<b>RESULTADOS E DISCUSSÕES .....</b>	<b>69</b>
<b>5.1</b>	<b>Como Utilizamos as Métricas de Avaliação.....</b>	<b>69</b>
<b>5.2</b>	<b>Resultados.....</b>	<b>70</b>
5.2.1	Experimento 1 .....	70
5.2.2	Experimento 2 .....	71
5.2.3	Experimento 3 .....	74
5.2.4	Experimento 4 .....	77
<b>5.3</b>	<b>Discussões dos Resultados .....</b>	<b>82</b>
<b>5.4</b>	<b>Resumo do Capitulo .....</b>	<b>83</b>
<b>5.5</b>	<b>Tabelas .....</b>	<b>83</b>
<b>6</b>	<b>CONCLUSÃO.....</b>	<b>91</b>
	<b>Referências .....</b>	<b>93</b>

---

# Introdução

A coerência textual pode ser definida como um conceito lógico que nos remete a unidade, relação e continuidade de sentidos em uma obra literária. Segundo Aline Evers (EVERS, 2013), as marcas essenciais em textos coerentes são: a manutenção de tópicos, a progressão textual, a articulação textual e a não contradição. Essa são as mesmas marcas que fazem um texto eficiente em leitura. A coerência textual proporciona uma conexão entre o texto e a representação mental do leitor (GRAESSER et al., 2004), fazendo com que este compreenda o conceito e as intenções que o autor quis transmitir. Assim, a coerência textual é essencial na construção de qualquer conteúdo literário, seja ele produzido por um ser humano ou gerado automaticamente por uma ferramenta computacional, como na tradução automática.

A tradução automática é estudada desde o início do século passado, mais precisamente desde o final da década de 30 e início da década de 40 (HUTCHINS, 1995). Desses tempos até os dias atuais, muitas abordagens tem sido propostas, entre elas, destacamos as baseadas em redes neurais, consideradas o estado da arte (WU et al., 2016) e, não menos importantes, as abordagens estatísticas, conceituadas por outros como fortes concorrentes (MENACER et al., 2017; CHÉRAGUI, 2012).

Dentre os vários obstáculos que ambas máquinas de tradução enfrentam para vencerem a tradução humana destacamos a coerência textual e, conseqüentemente, a relação semântica existente entre as sentenças de um texto. O fato de tanto o modelo neural quanto o estatístico, trabalharem a nível de sentenças ou seja, traduzindo individualmente cada frase, deve ter fortes implicações para a falta de coerência textual, situação que compromete a compreensão do leitor sobre o texto. Born e co-autores (BORN; MESGAR; STRUBE, 2017) afirmam que qualquer sistema computacional que gere textos como saída deve sempre procurar considerar a semântica textual existente no documento em questão.

Nesse trabalho científico, propomos estabelecer um modelo de coerência textual em textos traduzidos a partir do modelo de Born et al. (BORN; MESGAR; STRUBE, 2017) o qual utiliza um modelo de grafos. Nosso trabalho estende a proposta inicial não apenas pela aplicação à Língua Portuguesa mas também inova por trabalhar com classes gramaticais específicas, empregando os grafos de forma mais ampla que o modelo de Born e colaboradores, como veremos no Capítulo 3. Nossa proposta fundamenta-se na máquina



estatística de tradução Moses (KOEHN; KNOWLES, 2017), a qual, uma de suas funções, é gerar várias opções de tradução para cada frase do texto em questão. Sobre essas opções de tradução, construímos um grafo de coerência e identificamos e quantificamos as relações semânticas existente entre estas frases. Assim conseguimos selecionar a opção de tradução mais coerente, usando a teoria de grafos, quantificadas por duas métricas de avaliação.

No Capítulo 1, damos início a literatura de base relevante ou seja, aos trabalhos relacionados. Em seguida, explicamos nossos objetivos para melhorar o estado da arte da tradução automática. O capítulo 3, descreve nosso modelo de coerência baseado em grafo, aplicado após a emissão das três melhores traduções de cada sentença de um texto por meio do tradutor Moses. Posteriormente explicamos os experimentos realizados para então, apresentarmos e discutirmos os resultados obtidos no capítulo 5. Conclusão e possíveis trabalhos futuros estão comentados no capítulo 6, a qual finaliza este trabalho.

---

# Referencial Teórico

A tradução automática tem sido objeto de estudos a muitos anos. Nesse intervalo de tempo, muitos modelos de máquina de tradução foram propostos mas, ainda nenhum deles produziu resultados a nível humano.

O início desse capítulo trará uma breve definição sobre o que é a tradução automática e como funcionam duas máquinas de tradução contemporâneas. Daí, mostraremos um problema que ambas as máquinas compartilham quanto as traduções que elas produzem.

Posteriormente, mostraremos a definição de coerência textual para em seguida, descrevermos alguns modelos computacionais que abordam o tema. Nessa etapa, após uma breve apresentação, evidenciaremos os modelos de coerência baseados em grafos os quais tem tido êxito com relação ao tema.

Daremos destaque também a existência de poucos trabalhos que abordam a coerência textual no campo da tradução automática. E, dentre os poucos trabalhos encontrados, destacaremos um que utilizou modelos de coerência baseados em grafos e explicaremos como ele funciona.

## 1.1 Tradução Automática

A tradução automática ou tradução mecânica, como também é conhecida, é uma das áreas mais complexas do campo científico de PLN. Evidentemente seu propósito está associado ao estudos e desenvolvimento de metodologias e técnicas de elaboração e construção de sistemas computadorizados para a produção de traduções linguísticas, ou seja, traduzir automaticamente uma língua natural para outra, com ou sem assistência humana (HUTCHINS; SOMERS, 1992). Ela é estudada desde o início do século passado, mais precisamente no final da década de 30 e início da década de 40 (HUTCHINS, 1995). De lá para cá, muitas abordagens tem sido propostas pelos pesquisadores. Dentre as muitas existentes, destacamos as abordagens estatísticas (CHÉRAGUI, 2012), (MARTINS;

CASELI, 2013) e as baseadas em redes neurais (WU et al., 2016).

## 1.2 Máquina de Tradução Estatística

Durante 20 anos, as máquinas de tradução estatísticas (Statistical Machine Translation – SMT) foram consideradas o estado da arte nesse campo de estudo (WU et al., 2016). Treinadas por meio de corpus bilíngue, elas utilizam análise estatísticas e algoritmos preditivos para realizar traduções de documentos inteiros.

As máquinas estatísticas de tradução são basicamente compostas pelos modelos de tradução e de linguagem, além do decodificador da máquina (KOEHN; OCH; MARCU, 2003). Eles são respectivamente responsáveis pela tradução, fluência e seleção da melhor sentença alvo em detrimento da sentença fonte.

Essas máquinas de tradução podem ser abordadas de diversas formas entretanto, a mais utilizada e eficiente é a baseada em frases (LOPEZ, 2008). Esse modelo propõe segmentar as sentenças de um texto em diversos pedaços, variando a cobertura entre uma ou mais palavras para a partir desse ponto, construir a tradução de uma sentença.

O princípio de funcionamento de uma máquina estatística de tradução está no modelo matemático conhecido como distribuição de probabilidades. O qual quantifica a possibilidade de ocorrência de um certo valor para a variável em estudo. Assim, a máquina consegue selecionar a melhor tradução (a mais provável) de uma sentença fonte (em inglês), para uma sentença alvo (português).

## 1.3 Máquina de Tradução Neural

Atualmente, há quem considere as máquinas de tradução neurais (Neural Machine Translation – NMT) o estado da arte nesse campo de estudos. Elas, assim como as máquinas estatísticas de tradução, são treinadas por meio de corpus bilíngues e utilizam redes neurais para realizar análises probabilísticas na busca de padrões textuais (WU et al., 2016).

Muitas tipos de redes neurais foram utilizadas para a construção das máquinas de tradução que pertencem a esse gênero. Mas, foram as redes recorrentes que se saíram melhores, por terem sido projetadas especificamente para lidar com dados temporais e textuais (WU et al., 2016).

Utilizando uma arquitetura composta por um codificador e um decodificador, as redes neurais recorrentes utilizadas na tradução automática, conseguiram tratar problemas de previsão de sequências numéricas variáveis de uma forma eficaz. Isso porque quando o codificador da máquina recebe uma sentença fonte, cada palavra que a compõe é

transformada em uma sequência de números que são armazenados em um vetor de significado. Em seguida, o decodificador recebe esse vetor e transforma seus dados em outra sequência numérica por meio dos quais ele proporciona uma saída ou seja, a sentença traduzida (WU et al., 2016).

## 1.4 SMT vs. NMT

Ao compararmos as máquinas estatísticas de tradução com a neurais, podemos perceber um certo equilíbrio entre elas. As vantagens que uma obtém sobre a outra, são compensadas rapidamente por outras qualidades que a concorrente não tem. Isso torna a disputa entre elas bastante acirrada.

Os ganhos das máquinas de tradução neurais se concentram, quando comparadas as estatísticas, em gerar resultados que reduzem o esforço pós edição. Além disso, elas apresentam aparente vantagem sobre textos lexicalmente ricos e proporcionam erros morfológicos menores. Também oferecerem uma ordenação de palavras melhor, principalmente no tocante aos verbos (BENTIVOGLI et al., 2016).

Em contra partida, as máquinas de tradução estatísticas se sobressaem sobre as neurais quando trabalham com textos fora do seu domínio de treinamento Koehn e Knowles (2017). Elas também apresentam resultados melhores ao traduzirem sentenças extensas, com mais de 60 palavras. Além de exigirem menos recursos para seu treinamento que aliás, é realizado em menor tempo comparada as máquinas neurais Menacer et al. (2017).

## 1.5 Problemas com Ambas as Máquinas de Tradução

As máquinas de tradução estatísticas e neurais proporcionaram grandes avanços no campo da tradução automática. Mas, infelizmente ambas estão longe de apresentarem resultados a nível humano, que são concebidos considerando a relação semântica presente no texto (MENACER et al., 2017). Afinal, a maioria das máquinas de tradução estatísticas e neurais atuam apenas a nível de sentença, traduzindo uma por vez.

Quando um tradutor automático trabalha a nível de sentença, ele prejudica a coerência textual do documento traduzido. Pois, ao converter sequencialmente e independentemente uma sentença por vez, a máquina acaba desconsiderando a relação semântica existente entre elas. Assim, toda a ideia da obra acaba sendo afetada, comprometendo a compreensão do leitor já que a coerência textual fica comprometida. Podemos ver um

exemplo disso na Tabela 1 na página 20. Onde, por causa de uma palavra mal traduzida, o sentido do texto ficou comprometido.

Tabela 1 – Nessa tabela temos um texto simples composto por três sentenças. Na primeira coluna vemos a versão dele em inglês enquanto na segunda, sua correspondente tradução realizada por uma pessoa por fim, a versão traduzida por uma máquina de tradução neural (NMT). Perceba que há um erro gritante na última sentença no tocante a palavra olhar (segunda coluna) para visual (terceira coluna), implicando em uma desconectividade de sentido, alterando a interpretação da mensagem do texto em questão.

Texto em Inglês	Texto Traduzido por um Humano	Texto Traduzido por uma NMT
The world is beautiful as long as your eyes are simple. For beauty is in the eyes of the beholder and not in the image itself. You make the difference depending on how you look at it.	O mundo é muito belo desde que seu olhar seja singelo. Pois a beleza está no olhar de quem vê e não na imagem em si. A diferença quem faz é você, só depende do seu <b>olhar</b> .	O mundo é muito bonito, desde que seus olhos sejam simples. Pois a beleza está nos olhos de quem vê e não na imagem em si. A diferença quem faz isso é você, só depende do seu <b>visual</b> .

A coerência textual é fundamental em qualquer texto, pois ela é a responsável pelo desenvolvimento de todo o assunto. Pensando nisso, entendemos assim como Born, Mesgar e Strube (2017) que, qualquer sistema computacional que gere textos como saída, assim como os tradutores automáticos, devem sempre procurar considerar a semântica textual existente no documento em questão. Dessa forma, iniciamos a leitura de diversos artigos científicos na busca de uma solução para esse tipo de problema.

## 1.6 Coerência Textual

A coerência é um fenômeno linguístico responsável pela construção e interpretação de um texto. Ela deve ser entendida como um conceito lógico que nos remete a unidade, relação e continuidade de sentidos que nos permitem compreender o tema desenvolvido pelo autor (SILVA; TORRES; BRASIL, 2018). Para sua construção, o texto em si deve abranger diversos fatores linguísticos, cognitivos e interacionais dispostos ordinariamente (SILVA; TORRES; BRASIL, 2018). De modo que a não contradição, a manutenção de tópicos, a progressão e articulação textuais sejam marcas essenciais desse texto (EVERS, 2013). Promovendo uma sequência de sentenças relacionadas por meio de sinais linguísticos facilmente identificáveis. Tais dispositivos, permitem ao leitor interpretar cada sentença individualmente sem perder a ideia do texto como um todo. Ocasionalmente em uma leitura eficiente, que pode ser definida como a conexão de um texto com a representação mental do

leitor (GRAESSER et al., 2004). Assim, a coerência textual é essencial na construção de qualquer conteúdo literário, seja ele produzido por uma pessoa ou gerado automaticamente por uma ferramenta computacional, como na tradução automática (BORN; MESGAR; STRUBE, 2017).

## 1.7 Modelando Computacionalmente a Coerência Textual

Hoje em dia, principalmente com a Internet, uma grande quantidade de textos estão sendo produzidos e disponibilizados. Trabalhar computacionalmente com eles, tem sido objeto de estudos a um bom tempo na área de PLN. Dentre as muitas abordagens automáticas, a avaliação da coerência textual tem crescido nos últimos anos.

Modelar computacionalmente a coerência textual não é algo relativamente simples já que a abstração é uma de suas características. Por isso mesmo, não existe uma técnica automática absoluta que consiga avalia-la plenamente mas, diversos modelos que propõe molda-la. Tais modelos de coerência inclusive, estão proporcionando bons resultados, principalmente quanto a geração de resumos, análises e criação de documentos.

A maioria dos modelos automáticos para a coerência textual, procuram abordá-la de maneira local ou global conforme (ELSNER; AUSTERWEIL; CHARNIAK, 2007). De maneira local quando, a busca por boas conexões se concentra sobre sentenças adjacentes que apresentam uma coesão lexical, compartilhando entidades (palavras) iguais ou semelhantes. E global para avaliações a nível de discurso, onde conexões entre sentenças distantes são observadas ou mesmo, entre parágrafos adjacentes.

A grade de entidades (BARZILAY; LAPATA, 2008), é um bom exemplo de modelo automático desenvolvido para avaliar a coerência textual. Esse modelo propõe identificar a coerência local, representando elementos de um texto em uma matriz. Por meio dela, é possível reconhecer sentenças adjacentes que apresentam uma relação semântica caracterizada pelo compartilhamento de palavras iguais ou semelhantes. Através dessa técnica, muitas aplicações foram desenvolvidas como avaliação de artigos científicos e de resumos produzidos automaticamente.

O outro exemplo de automação, é o modelo de conteúdo (LAPATA; BARZILAY, 2005) que propõe avaliar a coerência textual no âmbito global. Esse modelo busca capturar a coerência textual, mediante a identificação e extração dos tópicos presentes no texto. Onde os tópicos devem ser entendidos como o estado oculto presente em sentenças que são observadas. Ao final, a coerência global de um texto é resumida mediante a probabilidade geral da mudança de tópico da primeira para a última sentença. Esse

modelo, foi originalmente utilizado na extração de informações de artigos científicos e também, na produção automática de resumos coerentes.

Em 2011, um modelo que trata a coerência textual no âmbito das relações discursivas foi apresentado. Desenvolvido por Lin, Ng e Kan (2011), o modelo busca identificar e classificar as relações entre sentenças adjacentes que, compartilham entidades pertencentes a uma mesma classe gramatical. Por meio de uma matriz semelhante a grade de entidades, os pesquisadores classificaram as relações discursivas por meio do corpus PDTB. Assim, por meio de seu modelo, eles conseguiram identificar documentos coerentes de outros, cujas as sentenças estavam dispostas desordenadamente.

Recentemente, modelos de coerência a base de grafos foram propostos no tratamento textual. Os grafos são uma técnica pertencente a matemática discreta. Eles são compostos por vértices (nós) e arestas (links) pelos quais conseguimos ilustrar um conjunto de objetos e a relação existente entre eles (PEREIRA; CÂMARA, 2008).

Esses modelos de coerência baseado em grafos têm apresentado resultados superiores a outros modelos como no caso da grade de entidades. Nas próximas seções apresentaremos alguns desses modelos, explicando como eles funcionam.

## 1.8 Grafos de Entidade

Inspirados pela grade de entidades de Lapata e Barzilay (BARZILAY; LAPATA, 2008) e pelo modelo de coerência baseado em grafos de Guinaudeau e Strub (GUINAUDEAU; STRUBE, 2013), Mesgan e Strub (MESGAR; STRUBE, 2015) criaram um modelo que aborda a relação semântica entre sentenças pertencentes a um texto.

A lógica por trás do modelo de coerência criado por eles é muito simples. A partir das sentenças observadas, eles propõe selecionar todos os substantivos do texto. Em seguida, eles verificam a coocorrência desses substantivos (entidades) nas sentenças trabalhadas pelo modelo para a partir daí, identificarem as que tem substantivos em comum. Quando isso ocorre, uma ligação entre essas duas o mais sentenças é estabelecida por intermédio da palavra que elas compartilham. Caracterizando dessa forma, o que (MESGAR; STRUBE, 2015) vão classificar como relação semântica entre sentenças ou seja, coerência textual.

Para conseguirem modelar sua proposta, Mesgar e Strube (2015) utilizaram a técnica de grafos. Por meio dela, eles passaram a representar as sentenças e seus respectivos substantivos em vértices (nós) e a ligação entre eles, em arestas. Dessa forma, eles construíram um modelo de coerência que utiliza um grafo que é considerado bipartido. Pois, enquanto as sentenças compõe um conjunto de vértices, seus substantivos constituem outro conjunto de nós.

Mesgan e Strub (MESGAR; STRUBE, 2015) denominaram seu modelo de coerência como grafo de entidades. Com ele, os pesquisadores conseguiram identificar a relação semântica entre sentenças que eram ou não adjacentes. Expandindo dessa forma o modelo de grade de entidades (BARZILAY; LAPATA, 2008) e o modelo de coerência baseado em grafos de Guinaudeau Strube (GUINAUDEAU; STRUBE, 2013), que buscam observar apenas a coerência local nos textos onde são aplicados.

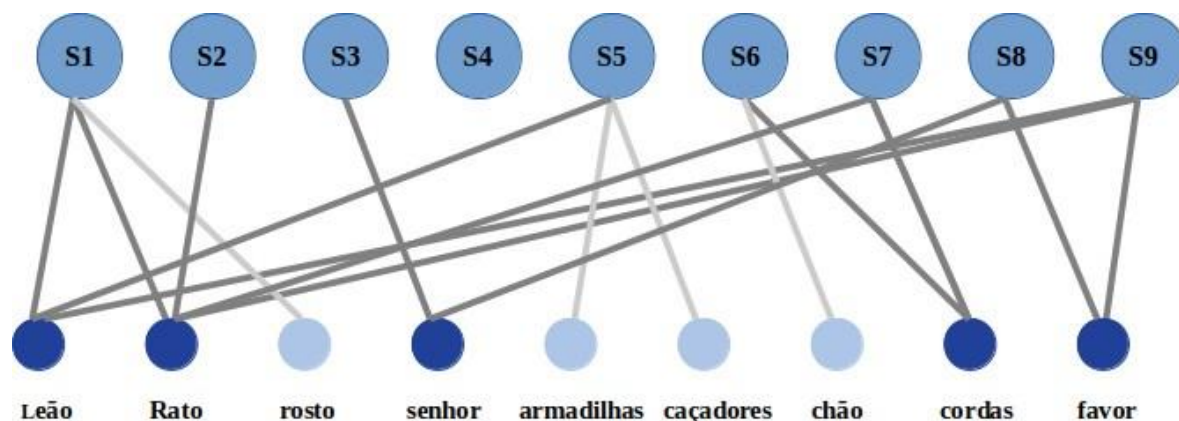
Para exemplificar, temos na Tabela 2 nove sentenças denominadas sequencialmente a partir de S1 a S9. No conteúdo de cada uma delas, destacamos em colchetes os respectivos substantivos que assim como as sentenças, são transformados em vértices no grafo de entidades. Na Figura 1 vemos o grafo de entidades formado com a inclusão das arestas que marcam a coocorrência das palavras destacadas nas sentenças. Nela, podemos perceber a representação de dois tipos de nós, caracterizados por círculos de dois tamanhos, pintados em três tonalidades de azul. Os maiores e em tonalidade intermediária, representam as nove sentenças que compõe o texto. Enquanto que os menores, inicialmente em azul claro, ilustram as entidades classificadas como substantivos presentes nas nove sentenças. Quando em uma das sentenças, qualquer das entidades estiver presente, uma aresta na cor cinza claro será estabelecida entre ambos os nós. Mas, caso uma mesma entidade seja compartilhada por duas ou mais sentenças, sua representação passará para um azul escuro e as respectivas arestas para um cinza mais denso.

Tabela 2 – Pequeno texto com 9 sentenças e seus respectivos substantivos identificados em colchetes.

Nome	Sentenças
S1	Um [Leão] dormia sossegado, quando foi despertado por um [Rato], que passou correndo sobre seu [rosto].
S2	Com um bote ágil ele o pegou, e estava pronto para matá-lo, ao que o [Rato] suplicou:
S3	"Ora, veja bem, se o [senhor] me poupasse, tenho certeza de que um dia poderia retribuir seu gesto de bondade..."
S4	Apesar de rir por achar ridícula e improvável tal possibilidade, ainda assim, como não tinha nada a perder, ele resolveu libertá-lo.
S5	Aconteceu que, pouco tempo depois, o [Leão] caiu numa [armadilha] colocada por [caçadores].
S6	Assim, preso ao [chão], amarrado por fortes [cordas], completamente indefeso e refém do fatídico destino que certamente o aguardava, sequer podia mexer-se.
S7	O [Rato], reconhecendo seu rugido, se aproximou e roeu as [cordas] até deixá-lo livre.
S8	Então disse: "O [senhor] riu da simples ideia de que eu, um dia, seria capaz de retribuir seu [favor].
S9	Mas agora sabe que, mesmo um pequeno [Rato], é capaz de fazer um grande [favor] a um poderoso [Leão]..."



Figura 1 – Grafo de Entidades gerado mediante o texto apresentado na Tabela 2.



## 1.9 Grafo de Projeção

O grafo de projeção, inicialmente desenvolvido por Guinaudeau e Strub (GUINAUDEAU; STRUBE, 2013), é uma estrutura de conectividade que trabalha apenas com um conjunto de vértices que tem por objetivo representarem as sentenças de um texto. Para sua construção, Mesgan e Strub (MESGAR; STRUBE, 2015) tomaram emprestado o conceito do grafo de entidades para identificar a relação semântica entre sentenças de um texto e assim, conseguirem modelar a coerência textual.


Diferentemente do modelo de coerência baseado em grafos de Guinaudeau e Strub (GUINAUDEAU; STRUBE, 2013) e do grafo de entidades criado por Mesgan e Strub (MESGAR; STRUBE, 2015), os grafos de projeção sempre trabalham com arestas direcionais ou seja, aquelas que indicam um sentido. O objetivo é manter a ordem textual e assim, conservar o desenvolvimento do assunto, mediante a relação semântica entre sentenças.

Apesar de serem uma compilação dos grafos de entidades, os grafos de projeção podem ser trabalhados de diversas maneiras, incluindo ponderações em suas arestas. Logo mais, na Figura 2 apresentamos um grafo de projeção simples (sem ponderação), construído em torno das palavras “leão” e “rato”, conforme o texto apresentado na Tabela 2.

## 1.10 Grafos de Relações Discursivas

As Relações discursivas são elementos abstratos responsáveis pela conexão de segmentos textuais que acontecem mediante o desenvolvimento do discurso. Elas são muito importantes e estão sempre presentes em textos classificados como coerentes.

Figura 2 – Neste exemplo temos um Grafo de Projeção elaborado a partir do conceito do Grafo de Entidades mostrado na Figura 1, página 24. Nele, vemos as sentenças do texto da Tabela 2 (pág. 23) representadas por vértices e a relação semântica entre elas por arestas direcionais.



!

Impulsionados pelo modelo de coerência elaborado por Lin, Ng e Kan (2011), Mesgan e Strub criaram os grafos de relações discursivas. Por meio deles, os pesquisadores procuraram modelar a coerência textual de uma forma prática e dinâmica. Onde as sentenças são os vértices e as arestas direcionais as relações discursivas.

Para identificarem e classificarem as relações discursivas entre os segmentos textuais, Mesgar e Strube (2015) utilizaram o corpus Penn Speech Treebank (PDTB). Nele, há diversas anotações padronizadas referentes as estruturas e semânticas presentes nos discursos. Assim, eles conseguiram obter grafos que inclusive apresentavam vértices auto relacionáveis, já que podem haver mais de um segmento textual em uma mesma sentença.

Os grafos de relações discursivas criados por Mesgan e Strub podem inclusive, serem aplicados com pesos. Onde as arestas (relações discursivas) são ponderadas conforme o número conexões que um vértice pode apresentar consigo mesmo e com outras sentenças. Dessa forma, caso uma sentença S1 (vértice) apresente duas relações discursivas com a frase S2, a respectiva aresta direcional entre elas, será ponderada com o algarismo 2.

Logo mais na página 26 na Figura 3, apresentamos dois grafos de relações discursivas onde um é ponderado (arestas pontuadas) e o outro não.

Figura 3 – A esquerda vemos um grafo de relações discursivas (RD) não ponderado e a direita temos o mesmo grafo RD com pesos em suas arestas. Ambos construídos a partir do corpus Penn Speech Treebank. Observação: esse exemplo foi construído e não tem qualquer relação com o texto apresentado na Tabela 2 (pág. 23).



## 1.11 Coerência Textual na Tradução Automática

Conseguir modelar a coerência textual na tradução automática é, sem dúvida, uma aspiração antiga nesse campo de estudos. Até onde sabemos, existem pouquíssimas publicações que abordam esse tema e, dos poucos trabalhos encontrados sobre ele, a maioria foca apenas no aspecto conceitual (BORN; MESGAR; STRUBE, 2017).

Em nossa busca, encontramos dois trabalhos que abordam o tema na prática. O primeiro, uma pesquisa de Xiong, Zhang e Wang (2015), sugere modelar a coerência textual no documento de origem. Observando os tópicos desenvolvidos em cada sentença, eles constroem seu modelo que é disponibilizado a máquina de tradução. Por meio dele, a máquina constrói traduções que buscam manter o desenvolvimento dos tópicos conforme consta no texto original. Apesar de resultados promissores, os autores sugerem observar outras relações textuais importantes em futuros trabalhos.

O destaque vai para o segundo trabalho, uma pesquisa elaborada por Born, Mesgan e Strub (BORN; MESGAR; STRUBE, 2017). Nela, um conjunto de grafos lexicais foram utilizados a fim de modelar a coerência textual durante o processo de tradução. Como resultado, os pesquisadores conseguiram produzir traduções semanticamente mais coesas ou seja, mais coerentes. Na seção a seguir, detalharemos melhor esse trabalho que nos inspirou.

## 1.12 Um Modelo de Coerência Baseado em Grafos para a Tradução Automática

Como já vimos anteriormente, a coerência textual é algo relativamente abstrato e portanto, pode ser abordada de diversas maneiras. Dessa forma, antes de executarem seu experimento, Born, Mesgar e Strube (2017) definiram que tratariam o assunto pela perspectiva da progressão temática.

A progressão temática é um procedimento aplicado na construção de textos coerentes pois, ela proporciona organização e hierarquia das unidades semânticas. De modo que, o texto e suas sentenças conseguem desenvolver o tema de uma forma homogênea e enriquecedora (DANE, 1974). Portanto, ao abordarem a progressão temática, Born, Mesgar e Strube (2017) entenderam que ela deveria ser considerada apenas no idioma alvo, conforme a teoria elaborada por Toury (1995).

A teoria elaborada por Toury (1995) afirma que as relações textuais presentes em um documento são, frequentemente alteradas durante o processo de tradução. Ocasionalmente em diversas opções de tradução para cada elemento de um texto e por isso, deveriam ser consideradas. Assim, ao procederem dessa forma, Born e co-autores (BORN; MESGAR; STRUBE, 2017) propuseram modelar a coerência textual por meio de um conjunto de grafos lexicais aplicados somente ao Inglês.

O conjunto dos grafos lexicais é composto pelos conhecidos grafos de entidade, de projeção e também pelos seus respectivos subgrafos. Os subgrafos são subconjuntos de vértices que estão inclusos no conjunto de nós que compõe um grafo de projeção. Eles são importantes pois apresentam características semelhantes as encontradas na progressão temática (DANE, 1974). Portanto, é neles que os pesquisadores concentraram seus esforços já que, apresentam um padrão semântico forte entre sentenças. Assim, Born, Mesgar e Strube (2017) passaram a classificá-los como padrões de coerência em seu trabalho.

Antes de começarem a trabalhar com padrões de coerência durante o processo de tradução, Born e companhia precisaram adquirir um conjunto de padrões de coerência por meio dos quais pudessem realizar seu experimento. Dessa maneira, eles construíram seus grafos lexicais em documentos redigidos em inglês, pertencentes ao banco de dados DiscoMT. Ao extraírem as stop words desses documentos, eles utilizaram as palavras (entidades) restantes para construírem seus grafos. Utilizando um embeddings de palavras denominado GloVe (PENNINGTON; SOCHER; MANNING, 2014), os pesquisadores calcularam a relação de cosseno entre pares de entidades pertencentes a sentenças distintas. Caso o resultado correspondesse a 0,85 ou mais, uma aresta era estabelecida entre os vértices (sentenças). Ao final, por meio do algoritmo unificado GASTON (NIJSSSEN; KOK, 2005), o cientistas extraíram e armazenaram os subgrafos (padrões de coerência) de três,

quatro e cinco vértices exemplificados nas Figuras 4, 5 e 6.

Figura 4 – Exemplo de Subgrafos de 3 nós com suas respectivas identificações, citado na subseção 1.12 (página 27).

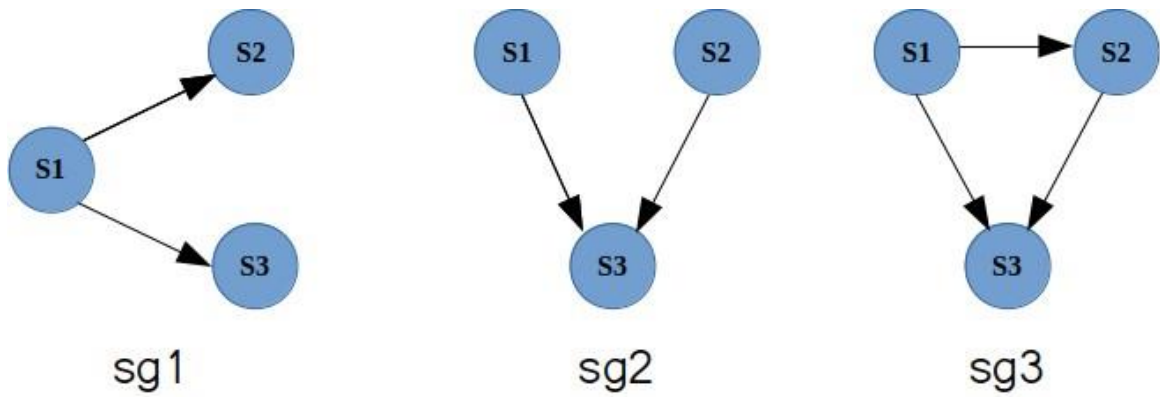


Figura 5 – Exemplo de Subgrafos de 4 nós com suas respectivas identificações, citado na subseção 1.12 (página 27).





Figura 6 – Exemplo de Subgrafos de 5 nós com suas respectivas identificações, citado na subseção 1.12 (página 27).



A ideia para extraírem e trabalharem apenas com padrões de coerência constituídos por três, quatro e cinco vértices (nós) pode ser explicada por dois motivos simples, detectados por Born, Mesgar e Strube (2017). O primeiro, consiste em padrões de coerência pobres observados em subgrafos com menos de 3 vértices enquanto o segundo, está atrelado aos resultados decrescentes proporcionados por subgrafos com mais de cinco nós. Assim, com seu conjunto de padrões de coerência formado, Born e co-autores treinaram a máquina de tradução Docent.

O Docent (HARDMEIER et al., 2013) é uma máquina estatística de tradução que trabalha a nível de documento e portanto, produz hipóteses de tradução que correspondem ao texto inteiro. Assim, para criá-las, o decodificador utiliza uma função objetiva que a cada passada pelo documento, promove modificações em sentenças, frases e palavras. Dessa forma, a máquina busca produzir hipóteses de tradução cada vez melhores, até chegar na que considere ideal.

Para seu experimento, Born, Mesgar e Strube (2017) utilizaram 12 textos previamente separados do DiscoMT os quais, foram submetidos ao Docent um a um. Conforme iam sendo submetidos, grafos lexicais foram sendo criados durante o processo de tradução de cada um deles. Mediante uma função recursiva, adicionada a função objetiva do decodificador, os pesquisadores conseguiram fazer com que o Docent levasse em consideração a relação semântica entre as sentenças durante o processo de tradução. Portanto, conforme os grafos eram concebidos a cada hipótese produzida, padrões de coerência de 3, 4 e 5 vértices eram selecionados para em seguida, terem seus pesos calculados.

Para calcular os pesos de cada padrão de coerência extraídos de um grafo  $G_s$ , Born, Mesgar e Strube (2017) propuseram dividir a contagem de cada subgrafo de  $k$ -nós ( $w(sg_k^s)$ )

pelo total de subgrafos  $(sg^k, G_s)$  também de  $k$ -nós, onde  $k \in \{3, 4, 5\}$ . Em seguida, eles utilizaram cada um desses pesos na função recursiva desenvolvida e denominada por eles como função de coerência  $h_{\text{coh}}(S)$ . A qual também propõe considerar o conjunto de padrões de coerência (FSG) armazenados pelo GASTON. Dessa forma, temos a seguinte função de coerência (1.1) implementada a função objetiva do Docent:

$$h_{\text{coh}}(S) = \sum_{sg_i^k \in \text{FSG}} \text{count}(sg_i^k, G_s) \cdot w(sg_i^k) \quad (1.1)$$

Com isso, os cientistas conseguiram influenciar o decodificar na escolha de quais sentenças ele deveria manter na construção de cada hipótese de tradução. Conseguindo conservar a cada passada pelo documento, as sentenças que apresentassem uma relação semântica melhor e portanto, uma tradução final mais coerente.

## 1.13 Resumo do Capítulo

Nesse capítulo pudemos perceber que a coerência textual não é algo fácil de ser computacionalmente modelado. Ainda mais no campo de estudos da tradução automática que apresenta poucas abordagens praticas quanto a esse assunto.

Dentre os poucos trabalhos na tradução automática, destacamos o realizado por Born, Mesgar e Strube (2017) que além de explorarem o campo, trouxeram uma grande inovação para a abordagem. Ao trabalharem com grafos durante o processo de tradução, eles conseguiram influenciar o decodificador da máquina de tradução e assim, obterem traduções melhores ao considerarem as relações semânticas entre as sentenças.

Motivados pelo trabalho de Boren e co-autores, apresentaremos no próximo capítulo nossos objetivos para o desenvolvimento de nossa abordagem.

---

# Objetivos

## 2.1 Objetivo principal

Inspirados por Born, Mesgar e Strube (2017), nós buscamos, por meio da teoria de grafos, contribuir para uma melhora no estado da arte da tradução automática. Nós pretendemos produzir traduções de textos curtos, que sejam mais coesos do ponto de vista semântico. Assim, com o auxílio dos grafos, nós buscamos identificar e selecionar as sentenças traduzidas que melhor se relacionam semanticamente entre si para, a partir daí, gerarmos textos traduzidos que sejam mais coerentes. Pretendemos gerar uma tradução semelhante a uma tradução humana, ou que pelo menos se assemelhe a tal, de modo que a leitura das sentenças seja mais uniforme e agradável.

## 2.2 Objetivos secundários

- Adquirir uma máquina de tradução automática;
- Entender como a máquina de tradução selecionada funciona;
- Definir nosso modelo de coerência baseado em grafos e como o utilizaremos;
- Determinar nossos experimentos;
- Encontrar corpora paralelos em inglês e português para treinar a máquina de tradução;
- Treinar a máquina de tradução com as corpus paralelos;
- Obter corpora paralelos em inglês e português para os testes;
- Realizar os testes usando nosso modelo de coerência na tradução automática;



- Obter traduções segundo nosso modelo de coerência baseado em grafos;
- Qualificar cada tradução emitida que utilizou ou não a nossa técnica;
- Comparar as traduções com nossa técnica com as que não a utilizaram;

---

## Metodologia

Visando uma proposta diferente quanto a modelar a coerência textual na tradução automática, apresentaremos nesse capítulo as técnicas que utilizamos para desenvolver nosso método.

Começaremos referenciando a máquina de tradução que empregamos, o Moses. Mostraremos os motivos que nos levaram a selecioná-lo e explicaremos como o utilizamos.

Posteriormente justificaremos a escolha pelos substantivos, adjetivos e verbos como o conjunto de termos utilizados para encontramos a relação semântica entre sentenças traduzidas.

Finalizaremos exibindo como nosso modelo de coerência baseado em grafos é construído e como por meio dele, conseguimos emitir traduções mais coesas.

### 3.1 Moses

O Moses é um sistema de tradução estatístico desenvolvido por Philipp Koehn para atender projetos na esfera acadêmica e comercial. (KOEHN et al., 2007). Ele é regulamentado pela a licença LGPL (Lesses General Public License) e possui uma vasta comunidade que oferece suporte e constantes atualizações (KOEHN, 2013).

A máquina de tradução Moses é constituída por um decodificador de código aberto e é acompanhada por um kit de ferramentas que a auxiliam. Ela está apta a ser configura para trabalhar com qualquer par de idiomas, contanto que exista corpus paralelos (LOPEZ, 2008) para isso.

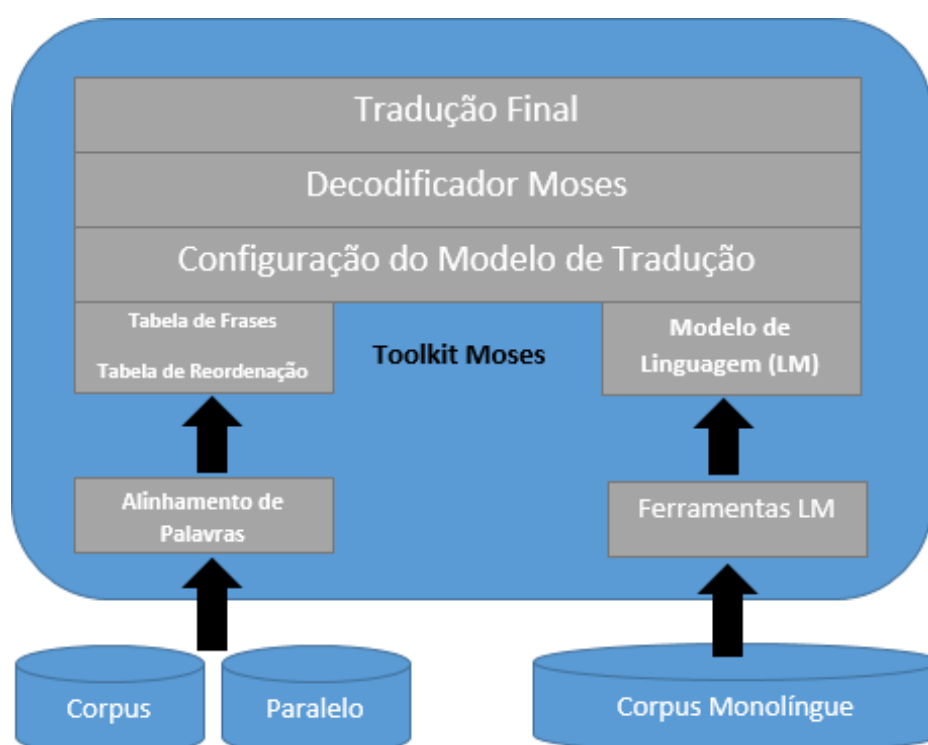
Quando o Moses é treinado, ferramentas de sua pipeline como o Giza++ e o KenLM usam os corpus paralelos para construir seus respectivos modelos de tradução e de linguagem. Por meio deles, o decodificador da máquina gera traduções de textos inteiros, sentença a sentença conforme seu modo operante.

O Moses oferece três modos operantes que definem como o decodificador vai traduzir. O primeiro é o baseado em frases, cujo o princípio está na quebra de sentenças no idioma fonte para construir sentenças no idioma alvo. O segundo, baseado em sintaxe, utiliza árvores de análise para construir sentenças traduzidas a partir de considerações gramaticais. Por último, o modo fatorado (CASELI; NUNES, 2009b), é uma extensão do baseado em frases que, além de fragmentar sentenças, também consegue associar a cada palavra questões morfológicas e sintáticas (KOEHN, 2013).

Essa máquina de tradução possui diversas funcionalidades que abrem um leque para quem a utiliza. Um exemplo é o Servidor Moses, por meio do qual arquivos inteiros podem ser enviados a máquina para serem traduzidos por meio de uma interface xml-rpc de comunicação. Destacamos também a funcionalidade denominada NBest, onde as melhores traduções correspondentes a cada sentença são registradas e o usuário pode ter acesso.

Na Figura 7 (pág.34), podemos verificar uma ilustração da máquina de tradução Moses (JABIN; SAMAK; SOKPHYRUM, 2013) e verificarmos qual é a lógica de funcionamento dela.

Figura 7 – Esquematisação do funcionamento da máquina de tradução Moses. A esquerda, na parte inferior do desenho, vemos a utilização de corpus paralelos utilizados para a elaboração da tabela de frases (reponsável pela tradução dos textos). A direita, na base da ilustração, observamos a utilização de um corpus monolíngue, empregado na construção do Modelo de Linguagem da máquina (responsável pela fluência da tradução). Logo acima, ambos as tabelas construídas são evocadas para a configuração do modelo de tradução, utilizado pelo decodificador cuja a incumbencia é emitir a tradução de um texto qualquer.



## 3.2 O que nos levou a optar pelo Moses

O Moses é considerado uma das melhores máquinas estatísticas de tradução graças a eficiência de seu decodificador e também de seu kit de ferramentas. Quando comparado a outras máquina de tradução de mesmo gênero, seu desempenho mostra-se superior, como podemos verificar na Tabela 3 (pág. 35) (HOANG; KOEHN, 2008).

Tabela 3 – Comparativo entre a máquina de tradução Moses com outros dois decodificadores estatísticos baseadas em frases. Na tabela, temos o tempo gasto por cada um dos decodificadores na emiçãõ das traduções, o quanto de memória principal cada um deles utilizou no processo e na ultima coluna, a quantificação qualitativa de suas respectivas traduções conforme a métrica automática de avaliação BLEU, explicada mais adiante na Subseção 3.9.1, página 57.

	Tempo Gasto	Pico de Memória	BLEU
Pharaoh	99 min	46MB	19.57
Moses	69 min	154 MB	19.57
Phramer	649 min	1218 MB	19.44

Suas configurações são ótimas pois proporcionam diversas possibilidades ao usuário. Seu decodificador por exemplo, foi escrito de forma modular, permitindo ao usuário variar o processo de decodificação. Ele também consegue trabalhar em mult-threaded durante o processo de treinamento e tradução, dessa forma os processos são agilizados. Sua pipeline é ótima para criar modelos de linguagem e de tradução e por isso, ela é utilizada por outras máquina de tradução como o Docent.

Optamos em trabalhar com o Moses pelo modo operante de tradução baseado em frases. Esse modo apresenta um treinamento simples e resultados excelentes tanto que ainda é muito usado no mercado da tradução automática.

Por fim, o Moses é uma máquina estatística de tradução que está em constante evolução. Sua comunidade de usuários oferece excelente suporte e manutenções a esse sistema de tradução. Proporcionando melhorias constantes de forma que o desempenho e funcionalidades sejam melhorados cada vez mais.

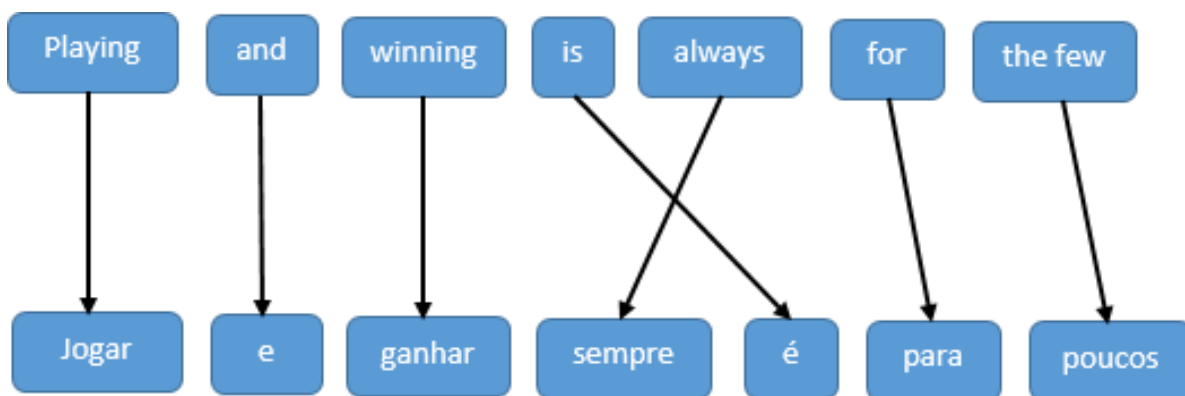
## 3.3 Modelo Baseado em Frases

### 3.3.1 Conceito de Frases na Tradução Automática

Na gramática, a palavra frase implica em um conjunto de termos (palavras) que juntas, apresentam um sentido completo. Porém, na tradução automática, frase é o nome dado a uma ou mais palavras que foram obtidas a partir da segmentação de uma sentença (NUNES;

CASELI, 2009). No caso, quando um texto em inglês é traduzido para o português, suas respectivas sentenças são quebradas em frases (partes menores) para posteriormente, serem traduzidas pelo decodificador. Em seguida, ele constroi cada uma das sentenças por meio de frases em português, juntando as peças como em um quebra cabeça. Ao olharmos para a Figura 8 (pág.36), podemos ver a grosso modo o processo de tradução baseado em frases entre uma sentença em inglês para uma tradução para o português. Observe que cada retângulo com palavras representa uma frase, as quais se encontram tanto no idioma fonte quanto no idioma alvo (CASELI; NUNES, 2009a).

Figura 8 – Exemplo simples do processo de tradução automática baseado em frases. Onde a primeira sentença em inglês, é dividida em partes menores (frases) enquanto a segunda, em português, é construída por meio de frases traduzidas conforme a sentença inicial.



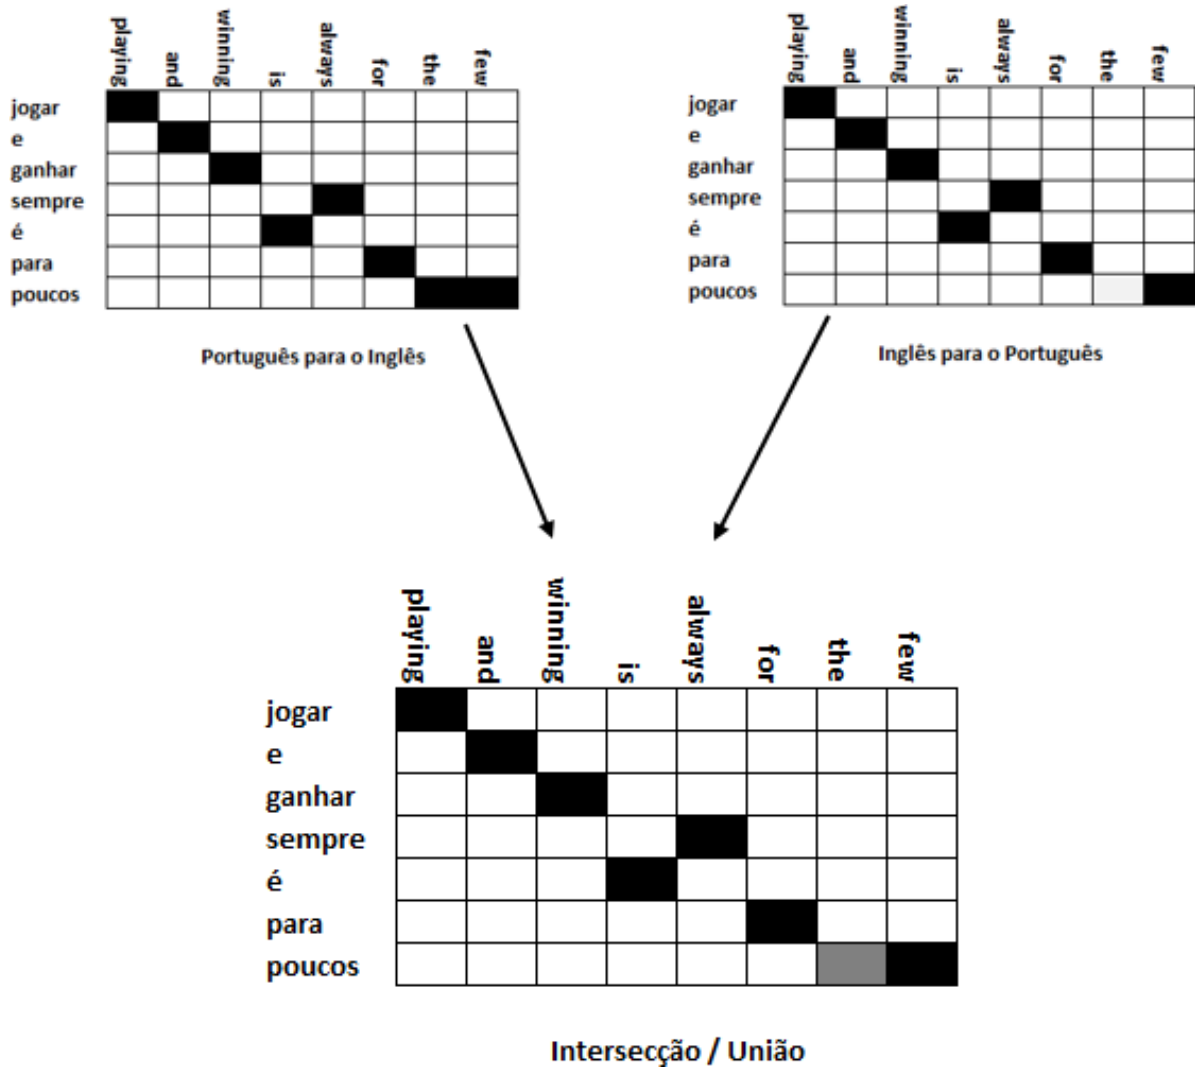
### 3.3.2 Alinhamento de palavras

O alinhamento de palavras é um procedimento padrão nas máquinas de tradução estatísticas. É por meio dele que as frases são obtidas. Neste processo, cada palavra no idioma fonte é alinhado com sua correspondente no idioma alvo. Na máquina de tradução Moses a ferramenta responsável por esse procedimento é o GIZA ++ (KOEHN, 2013). Desenvolvido na década de 1980 pela empresa IBM, a ferramenta realiza com eficiência essa tarefa. Através de um corpus paralelo, o GIZA++ elabora alinhamentos bidirecionais (HOANG; KOEHN, 2008), ou seja, ele gera dois tipos de alinhamentos. O primeiro, é construído a partir do idioma fonte para palavras no idioma alvo. Por sua vez, o segundo é construído de forma reversa, ou seja, por meio de palavras no idioma alvo para o idioma fonte. Em seguida, o GIZA++ realiza a fusão de ambos os alinhamentos gerando um alinhamento final mais amplo e portanto, com maior poder de tradução (KOEHN, 2013).

A Figura 9 na página 37, mostra-nos dois alinhamentos e sua respectiva fusão na qual existem pontos pretos e cinzas. Os pontos na cor preta correspondem a um

alinhamento preciso entre palavras (intercessão). Enquanto os pontos na cor cinza, são pontos adicionais, resquícios de intercessão nos alinhamentos primários.

Figura 9 – Tabela de alinhamento de palavras entre duas sentenças, do inglês para o português do português para o inglês e a união das tabelas.



O resultado gerado no alinhamento final é submetido ao beam search. Método utilizado pelo Moses que localiza frases que são disponibilizadas para o decodificador da máquina, que a partir delas emite uma sentença traduzida (KOEHN, 2013).

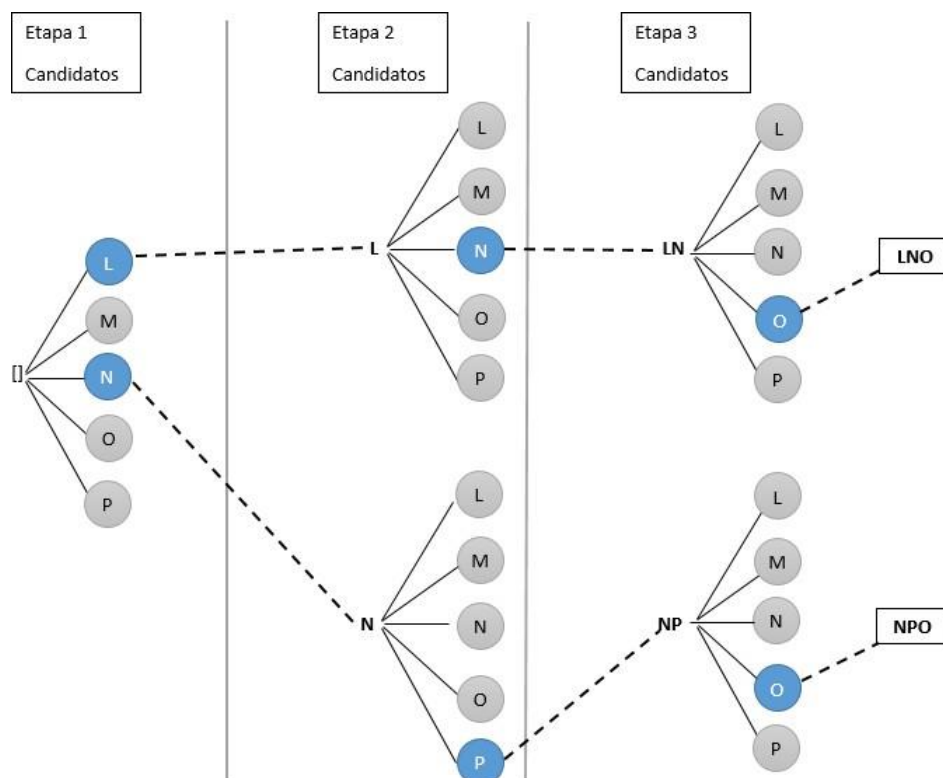
### 3.3.3 *Beam Search* – Pesquisa por Feixe

O *beam search* conhecido no português como busca ou pesquisa por feixes, é um algoritmo de pesquisa heurística. Baseado no método de pesquisa em grade (CARVALHO, 2018), ele busca selecionar os melhores resultados dentro de um conjunto de possíveis candidatos (TILLMANN; NEY, 2003). Esse algoritmo trabalha com um hiperparâmetro

ajustável conhecido como largura ou tamanho de feixe. Por meio dele, o algoritmo limita sua busca as melhores soluções parciais (CARVALHO, 2018). Dessa forma ele proporciona economia de memória e rápida solução na busca do seu objetivo. Sendo assim, a partir de um ou mais estados iniciais o beam search explora um grafo expandindo sua busca a outros vértices promissores, mediante o seu hiperparâmetro. Ele faz isso, até encontrar a hipótese que ele considera como a melhor solução (TILLMANN; NEY, 2003).

Para entendermos melhor o algoritmo beam search nós iremos demonstrar um exemplo simples. Suponhamos que temos um conjunto Y com 5 elementos (L, M, N, O e P) e que a partir deles, nós iniciamos a pesquisa até o objetivo. Definimos então que a busca será realizada em três etapas. Em cada etapa, propomos selecionar os dois melhores candidatos (elementos) pois nosso hiperparâmetro (tamanho de feixe) foi definido como 2. A partir dessa concepção, nós iniciamos a primeira etapa analisando cada um dos cinco (candidatos). Dentre eles, L e N foram destacados como os melhores dessa etapa. Dessa maneira, o algoritmo expande sua pesquisa aos próximos elementos, ampliando o grafo. Nessa segunda etapa, LN e NP são os mais prováveis segmentos dentre as possíveis dez combinações e é através deles que o *beam search* prossegue sua busca. LNO e NPO são os últimos candidatos selecionados por ele na terceira etapa, compondo dessa forma o todo de 6 candidatos ao posto de objetivo, sendo eles: L, N, LN, NP, LNO e NPO. Na Figura 10 (pág.38), está ilustrado o grafo pelo qual o beam search realiza sua pesquisa.

Figura 10 – Exemplo simples de como funciona o algoritmo *beam search* com três etapas de busca, onde em cada uma delas os dois melhores resultados são selecionados.



Para o conjunto  $Y$  temos agora os 6 melhores candidatos que foram alcançados mediante o parâmetro definido. Com isso, algoritmo *beam search* propõe analisar matematicamente um a um, para que dentre eles o melhor seja selecionado. Como podemos verificar, a pesquisa promovida pelo *beam search* é restrita a um campo específico de busca, ele vai afunilando até encontrar o candidato que considere ideal ou próximo do objetivo (KOEHN, 2013). Dado essas razões, esse tipo de algoritmo é comumente utilizado por muitos sistemas de tradução automática, os quais costumam trabalhar com grandes cálculos computacionais.

### 3.3.4 *Beam Search* Baseado em Pilhas no Decodificador Moses

O processo de tradução é iniciado assim que uma sentença no idioma fonte dá entrada no sistema Moses (KOEHN et al., 2007). Logo em seguida, o sistema começa a procurar opções de tradução para cada frase da sentença de entrada. Usando a tabela de tradução construída pelo Giza++, o Moses seleciona e separa as hipóteses (frases) mais adequadas para compor a tradução de toda a sentença. Após separadas, elas são encaminhadas ao decodificador e trabalhadas pelo algoritmo *beam search* (KOEHN, 2013). No exemplo a seguir, propomos traduzir uma frase em inglês para o português:

*Louise loves Peter.*

Com a seguinte tabela de frases (Tabela 4, pág.39):

Tabela 4 – Nessa tabela temos as palavras da sentença em inglês, mostrada anteriormente e as respectivas possíveis traduções (opções) para cada uma delas. É importante ressaltar que, no geral, um sistema automático de tradução não irá traduzir nomes próprios. Mas para exemplificar, nós estamos ignorando essa situação.

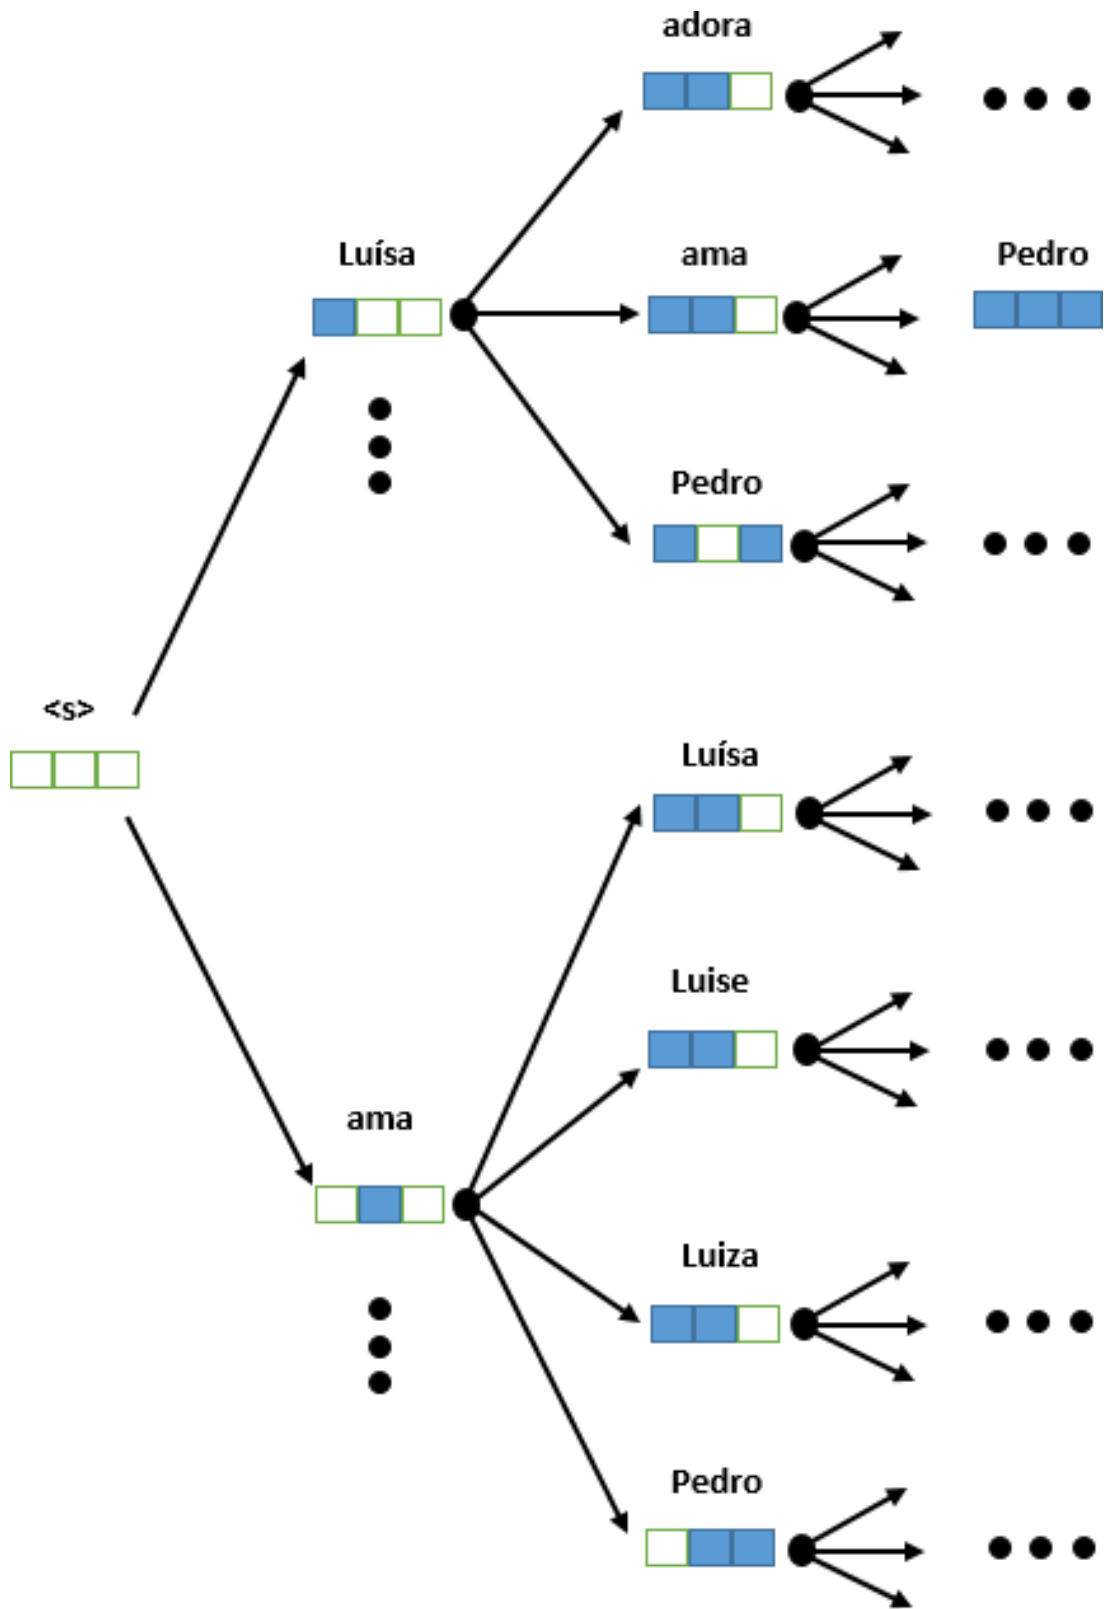
Inglês	Português
Louise	Lúisa
Louise	Luise
Louise	Luiza
loves	adora
loves	ama
Peter	Pedro

A Figura 11 na página 40, mostra-nos uma tradução completa da sentença “*Louise loves Peter*”. No processo, cada frase (hipótese) é considerada durante a construção da sentença traduzida. Sabemos que há uma tradução completa quando o vetor abaixo de cada hipótese, estiver completamente preenchido, ficando todo em azul.

A partir de um estado zero, diversas opções de frases são selecionadas como potenciais candidatas. Cada frase, pode apresentar um tamanho variado, podendo existir



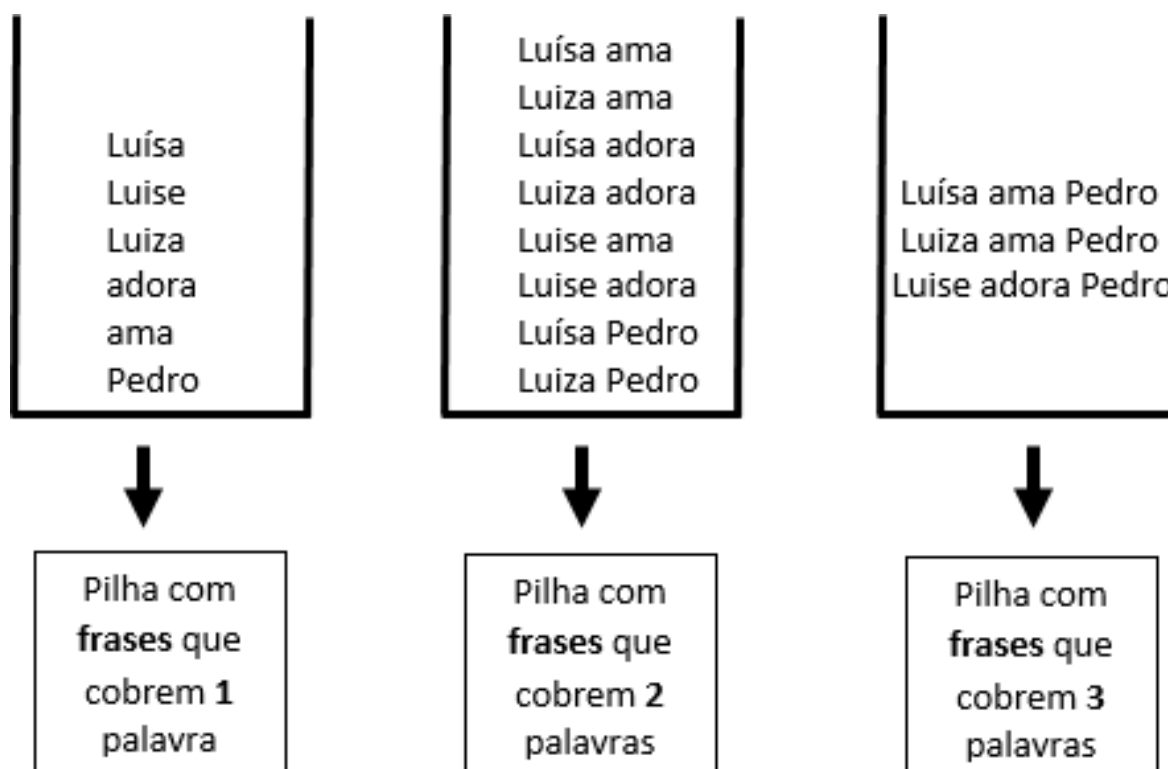
Figura 11 – Funcionamento básico do algoritmo beam search no decodificador Moses durante a construção tradutória da sentença “Louise loves Peter”.



opções que consigam cobrir toda a sentença a ser traduzida. Visando limitar a quantidade de opções e de evitar encontrar rapidamente uma frase que cubra toda a sentença, sem ao menos considerar as demais hipóteses, o sistema Moses procura trabalhar com pilhas, recombinação de frases e uma série de custos imputadas a cada uma das hipóteses de tradução (KOEHN, 2013).

Ao receber uma sentença e selecionar as opções de frases de tradução para essa sentença, o decodificador separa cada uma dessas hipóteses em pilhas específicas. Cada pilha irá armazenar hipóteses que apresentam o mesmo comprimento ou seja, que cobrem a mesma quantidade de palavras. Assim, hipóteses que cobrem apenas uma palavra, ficam armazenadas na pilha específica para elas (KOEHN, 2013). E as hipóteses que cobrem seis palavras, são armazenadas em outra pilha específica. A Figura 12 (pág.41) mostra as pilhas e suas respectivas hipóteses para a sentença: *Louise loves Peter*.

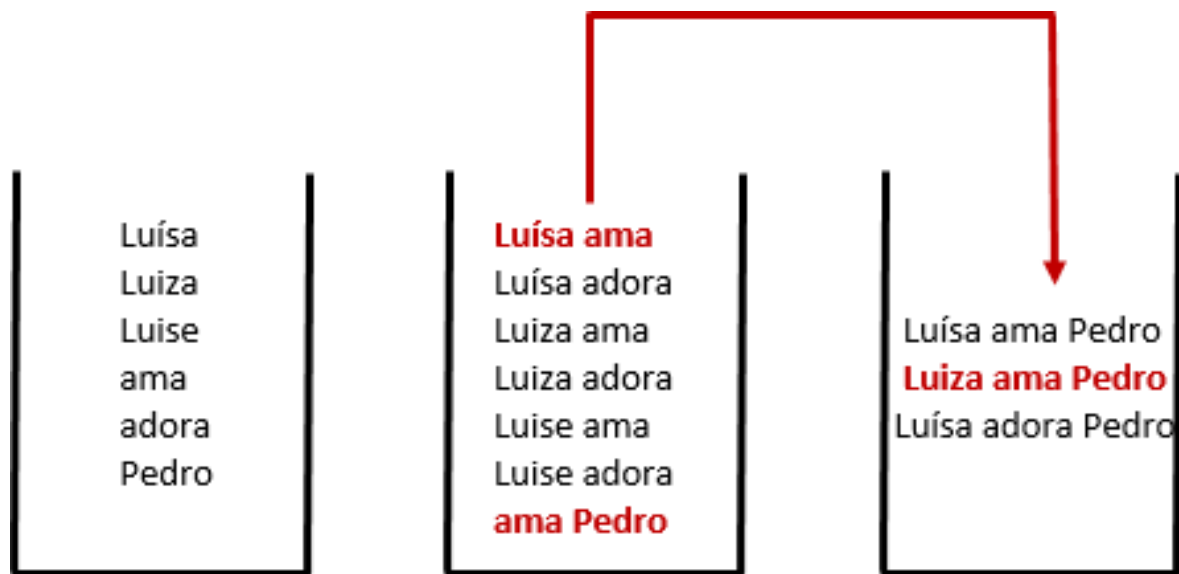
Figura 12 – Exemplo simples de pilhas conforme o tamanho das frases. Nele temos três pilhas onde uma é composta por frases que cobrem apenas uma palavra, outra com frases constituídas com duas palavras e a última com hipóteses (frases) que cobrem toda a sentença.



Durante o processo de análise de hipóteses, recombinações entre elas podem ocorrer. Isso é promovido pelo decodificador desde que essas hipóteses apresentem algumas características em comum, como: palavras estrangeiras cobertas, as duas últimas palavras no idioma alvo geradas e o final da última frase estrangeira coberta (KOEHN, 2013). Caso

haja uma recombinação, a nova hipótese será armazenada na pilha adequada, conforme o número de palavras que essa nova frase passa a cobrir. Para exemplificar, na Figura 13 (pág.42) mostramos a recombinação entre duas hipóteses e o resultado dessa operação sendo remanejado para a pilha adequada.

Figura 13 – Recombinação de duas hipóteses (frases) que cobrem duas palavras. Após a recombinação, a nova opção de tradução é deslocada para a pilha a qual deve pertencer ou seja, aquela que armazena frases que cobrem toda a sentença.

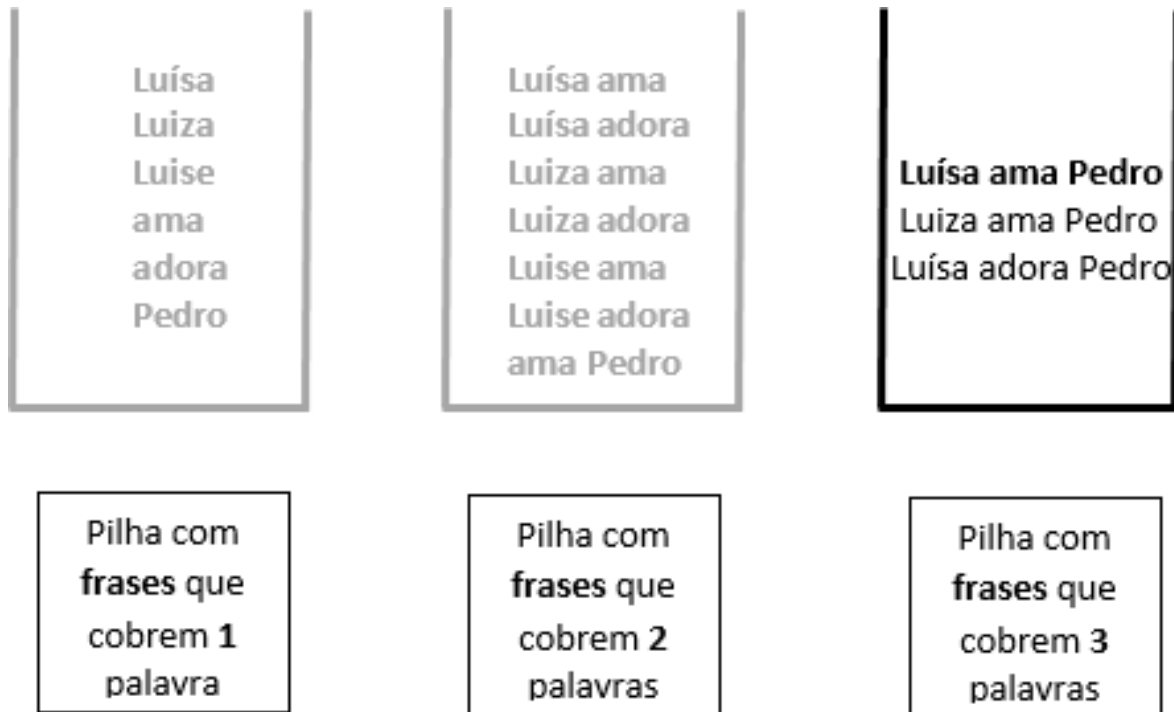


É vital que o decodificador controle o tamanho das pilhas, para que a memória não seja muito exigida e a pesquisa não perca tempo com hipóteses de custo irrelevante. Portanto, é natural que o decodificador promova podas ou mesmo eliminação de pilhas conforme julgar necessário (KOEHN, 2013). No final, a pilha com as hipóteses que cobrem todas as palavras da sentença estrangeira é a que vai ficar (KOEHN, 2013). E, dentre essas hipóteses, o decodificador analisará seus custos e selecionará a que for mais relevante ou seja, a que apresenta a melhor tradução da sentença estrangeira. Esse é o objetivo do algoritmo e consequentemente do sistema.

Na Figura 14 - página 43, temos a ilustração de três pilhas, geradas a partir da nossa frase: Louise loves Peter. Podemos ver que a única pilha em destaque é a que armazena as hipóteses que cobrem toda a sentença estrangeira.

A cada frase (ou hipótese) gerada pelo sistema, um custo será atribuído a ela. Se uma hipótese apresentar um custo alto, ela terá uma probabilidade baixa e portanto será pouca expressiva para o decodificador. Mas, quando o custo for baixo, a probabilidade da hipótese de tradução se torna alta e portanto, ela se transforma em uma forte candidata (KOEHN, 2013).

Figura 14 – A pilha em destaque armazena apenas frases que cobrem toda a sentença. Ao final do processo de tradução do Moses, esse será o único conteúdo considerado pela máquina de tradução pois, todas as demais pilhas são descartadas.



Basicamente o sistema Moses trabalha com dois tipos de custos obtidos por meio de outros custos. O custo atual e o custo futuro são os principais meios pelos quais o decodificador consegue mensurar a probabilidade de cada hipótese de tradução. No caso do custo atual, ele é alcançado mediante a multiplicação do custo original pelos custos de tradução, distorção e de modelo de linguagem. Apesar dele ser essencial para sabermos em que patamar está a hipótese, ele não acaba sendo suficiente. Pois ele tende a favorecer nas pilhas, aquelas frases que apresentam muitas opções de cobertura de tradução. Com isso, o sistema tende a produzir traduções de sentenças não tão boas. Na tentativa de resolver esse problema, o custo futuro passa a ser estimado também (KOEHN, 2013).

O custo futuro foi elaborado na tentativa de explicar a discrepância existente entre as muitas hipóteses que cobrem uma determinada palavra, para aquelas palavras que não são ou são pouco cobertas pelo sistema. Assim, para obter essa estimativa, o custo futuro é calculado por meio dos custos de tradução e modelo de linguagem, utilizando programação dinâmica. Pois esse tipo de estimativa está baseada na pontuação da tradução mais provável dos períodos restantes de uma sentença (KOEHN, 2013).

## 3.4 Lista NBest

Quando trabalhamos com qualquer sistema de tradução automático, nós esperamos pelo melhor resultado possível de tradução. Em se tratando de máquinas de tradução baseadas em frases, a frase mais provável será a selecionada no final como resposta (LOPEZ, 2008).

Como podemos verificar, geralmente os sistemas de tradução produzem muitas opções de frases que cobrem completamente uma sentença estrangeira. Assim, no caso do Moses, ao analisar a pilha correspondente a elas, o decodificador seleciona como resposta final a que apresenta menor custo e maior probabilidade (KOEHN, 2013).

Para fins de pesquisa, os desenvolvedores do Moses possibilitaram o acesso a essas frases que cobrem toda a sentença de entrada. A esse conjunto de opções, eles denominaram como Lista NBest (KOEHN, 2013) e é com ela que trabalhamos.

## 3.5 O que nos levou a optar pela Lista NBest

Assim como Born, Mesgar e Strube (2017) que se basearam nos estudos de Toury (1995), nós também propomos construir nosso modelo de coerência baseado em grafos apenas sobre textos no idioma alvo. Por isso, trabalhar com a lista NBest se tornou a melhor alternativa para nós pois, ela nos fornece quantas opções de tradução desejamos para cada sentença. As quais são registradas na lista ordinariamente, respeitando a ordem textual das sentenças a que pertencem. Devidamente separadas em grupos, dispostas de maneira decrescente conforme a pontuação avaliativa que elas receberam da máquina de tradução. Além disso, a lista NBest trouxe outra facilidade para nossa abordagem, proporcionando nos pouca interferência no funcionamento da nossa máquina de tradução já que por meio dela, temos acesso a uma variedade de potenciais progressões temáticas. Logo mais na Tabela 5, página 44, apresentamos três sentenças em inglês as quais submetemos a nossa máquina de tradução para fins de exemplificação. Em seguida, na Figura 15 (pág. 45), podemos ver um exemplo de Lista NBest construída a partir de três sentenças em inglês apresentadas na tabela anterior (Tabela 5, pág. 44).

Tabela 5 – Apresentamos três sentenças em inglês as quais submetemos ao Moses para obtermos um exemplo de lista NBest com as três melhores traduções de cada uma dessas sentenças.

<b>Identificação</b>	<b>Sentenças</b>
<b>Sentença 1</b>	My house is white.
<b>Sentença 2</b>	My car is red.
<b>Sentença 3</b>	My church is clean.

Figura 15 – Exemplo de Lista N-Best com relação as três melhores traduções das sentenças apresentadas na Tabela 5 pág. 44. Elas são apresentadas ordinariamente da primeira a terceira sentença, conforme o número de opções de tradução que optamos em trabalhar.

```

0 ||| minha casa branca é ||| Distortion0= -3 LM0= -34.252 WordPenalty0= -4 PhrasePenalty0= 4
TranslationModel0= -6.43569 -6.10912 -6.41902 -5.813 ||| -32.6095

0 ||| é a minha casa branca ||| Distortion0= -6 LM0= -32.087 WordPenalty0= -5 PhrasePenalty0= 4
TranslationModel0= -6.51634 -6.80149 -7.74692 -8.16785 ||| -32.6307

0 ||| é minha casa branca ||| Distortion0= -6 LM0= -32.8498 WordPenalty0= -4 PhrasePenalty0= 4
TranslationModel0= -6.43569 -6.10912 -6.41902 -5.813 ||| -32.8279

1 ||| meu carro vermelho ||| Distortion0= 0 LM0= -35.2241 WordPenalty0= -3 PhrasePenalty0= 3
TranslationModel0= -5.06571 -4.92714 -2.30256 -3.40644 ||| -29.3674

1 ||| o meu carro vermelho ||| Distortion0= 0 LM0= -36.0441 WordPenalty0= -4 PhrasePenalty0= 3
TranslationModel0= -5.11081 -5.61947 -3.98119 -6.17903 ||| -30.498

1 ||| meu carro , vermelho ||| Distortion0= 0 LM0= -37.3768 WordPenalty0= -4 PhrasePenalty0= 3
TranslationModel0= -6.25613 -4.92714 -4.55385 -5.50827 ||| -31.5373

2 ||| minha igreja limpo ||| Distortion0= 0 LM0= -35.4679 WordPenalty0= -3 PhrasePenalty0= 3
TranslationModel0= -5.18655 -4.67144 -3.97875 -2.97083 ||| -29.8698

2 ||| minha igreja limpas ||| Distortion0= 0 LM0= -35.5327 WordPenalty0= -3 PhrasePenalty0= 3
TranslationModel0= -5.25617 -4.87005 -3.90729 -2.83729 ||| -29.9341

2 ||| minha igreja é limpo ||| Distortion0= 0 LM0= -40.9475 WordPenalty0= -4 PhrasePenalty0= 3
TranslationModel0= -0.62389 -0.807389 -2.38807 -3.75608 ||| -29.9359

```

### 3.6 Como utilizamos a lista NBest

Após alguns testes com as listas NBest, percebemos que trabalhar com um número superior a três opções de tradução para cada sentença não é viável. Primeiro, porque muitas das opções que o sistema disponibiliza são completamente iguais a outras opções que inclusive aparecem entre as três melhores. Isso está diretamente relacionado ao caminho que o algoritmo beam search percorreu entre as frases para construí-la e por isso, recebem uma avaliação qualitativa diferente umas das outras, mesmo sendo iguais. O segundo motivo, tem a ver com a as opções de tradução que são diferentes, inclusive das três melhores qualificadas que trabalhamos. Elas são opções de tradução que costumam ser, em sua maioria, incoerentes e portanto, dispensáveis para nós.

## 3.7 Inovação

No trabalho de Born, Mesgar e Strube (2017), eles propuseram remover das sentenças as stop words já definidas na lista de Salton (1971), a qual tomaram como base. Dessa forma, eles passaram a trabalhar apenas com o as entidades que sobraram em cada sentença e a partir daí eles deram início a construção do seus grafos. Apesar de considerarmos o trabalho deles e te-lo como inspiração, escolhemos um caminho diferente. Baseado nos estudos de Mesgar e Strube (2015) e de Parveen, Mesgar e Strube (2016) os quais obtiveram bons resultados, optamos por considerar os substantivos presentes em cada opção de tradução de nossas sentenças, como entidades base para construirmos nossos grafos baseados em coerência.

Os substantivos pertencem a principal classe gramatical, são de extrema relevância quanto a relação semântica entre sentenças de um texto, como apontam Mesgar e Strube (2015). Por definição básica, substantivos são palavras que designam ou nomeiam os seres em geral, denotando coisas que já existem (GUIMARÃES, 2015). Para o nosso trabalho científico os consideramos imprescindíveis porém, na prática, eles não são os únicos termos que devem ser considerados. No decorrer do trabalho, pudemos perceber nos experimentos testes e em artigos a respeito de nosso idioma, que seria interessante considerarmos também os adjetivos e os verbos, além dos já definidos substantivos.

Os adjetivos são palavras que personificam o substantivo, conferindo a ele características, qualidades, estados ou aspectos. Eles pertencem a uma classe gramatical denominada adjunta (FREITAS, 2007) e procuram sempre se flexionar para se adequarem aos substantivos. A relação entre substantivo e adjetivo é tão forte que, em certos casos, ambos comutam funções, de modo que a classificação entre elas se torna flutuante ou seja, um tanto confusa (BAKHTIN, 1979). Nesse caso, apenas por meio de uma análise da iconicidade do signo verbal é que elas poderão ser percebidas separadamente (FREITAS, 2007).

Tanto os substantivos quanto os adjetivos podem vir a apresentar uma semântica discursiva e potencialidade grandes em uma sentença ou texto. Lapa (1977) define ambas as classes de entidades como dois aspectos de uma mesma realidade e portanto, fundamentais para exprimi-lo. Consequentemente, devido as suas características individuais e por essa relação relevante existente entre elas, nós optamos em incluir os adjetivos a nossa análise. Apesar disso, o adjetivo, assim como o substantivo, não serão as únicas classes gramaticais a serem analisadas por nós. Também propomos considerar a classe gramatical dos verbos.

Os verbos são uma classe gramatical variável, fundamental na estruturação de orações e sentenças (TRAVAGLIA, 1994). Eles propõem exprimir um tipo ação, estado ou mesmo fenômeno da natureza, podendo ser flexionados nas forma de: pessoa, número

, modo, formas, voz e tempo. Além disso, os verbos são responsáveis por normalizar os advérbios em uma sentença e pela caracterização do discurso em direto ou indireto. Assim, devido a sua complexidade e importância, vários estudos já foram realizados quanto a sua relevância no funcionamento textual-discursivo e em como ele está intrinsecamente relacionado a coerência textual.

Estudos como o de Travaglia (1994), provaram que os verbos exercem um papel de destaque na coesão e na coerência textual. Atuando como agentes de uniformidade através de referências (substituição e reiteração) e procedimentos linguísticos sequenciais (recorrência e progressão), proporcionando um contraste entre o primeiro e segundo plano presentes em um texto. Assim, os verbos conseguem organizar as informações da obra em essenciais e secundárias, através de relevância pragmática eles conseguem dar foco a um elemento da composição.

Observando e concluindo a importância das classes gramaticais denominadas substantivo, adjetivo e verbo, decidimos trabalhar com elas. Desta maneira, acreditamos que poderemos identificar relações semânticas entre nossas sentenças e portanto emitirmos traduções mais coerentes. Além do mais, provavelmente produziremos grafos menores e que exigirão um processamento menor, já que englobarão apenas três tipos de entidades, diferente do trabalho de Born, Mesgar e Strube (2017). Outrossim, entendemos que pode ser algo novo ao abordarmos dessa forma e quem sabe, uma nova alternativa e contribuição para futuros estudos na tradução automática.

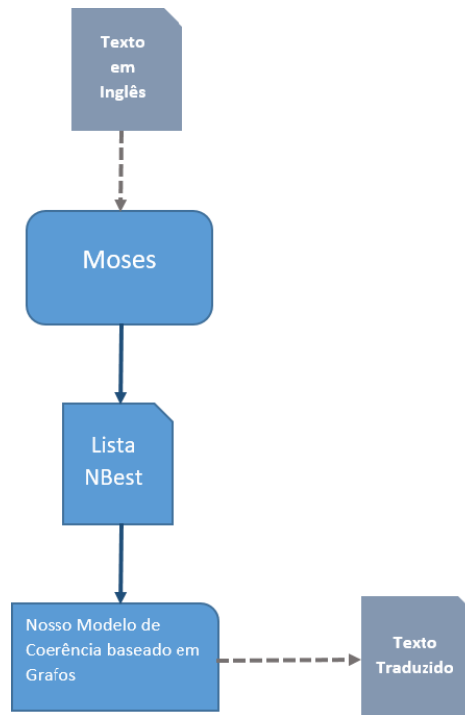
## 3.8 Construindo nosso modelo de coerência baseado em grafos

Ao submetermos um documento em inglês ao Moses, ao final do processo adquirimos uma lista NBest com as três melhores traduções de cada sentença. Sob essa lista, construímos nosso modelo de coerência que é baseado em grafos. Tendo como inspiração os modelo de grafos de entidade, de projeção com e sem ponderação (MESGAR; STRUBE, 2015), (MESGAR; STRUBE, 2016) e (BORN; MESGAR; STRUBE, 2017). Na Figura 16, página 48, mostramos a esquematização básica de nosso trabalho, desde a entrada do texto em inglês no processo até a emissão da tradução segundo nossa técnica de grafos.

Para construirmos nosso modelo de coerência, transformamos em vértices cada substantivo, adjetivo e verbo presentes nas opções de tradução da lista NBest. Depois, analisamos a relação de cosseno (aproximação) entre elas utilizando o algoritmo GloVe, desde que pertençam a mesma classe gramatical, a opções de tradução diferentes, atreladas a sentenças distintas. Caso apresentem uma aproximação equivalente a 0,75 ou mais, uma aresta direcional entre os vértices é estabelecida, enquanto suas respectivas opções de




Figura 16 – A base do funcionamento do nosso projeto. Enviamos um texto em inglês a máquina de tradução Moses para em seguida, obtermos uma lista NBest com as três melhores traduções de cada sentença. Em seguida, aplicamos nosso modelo de coerência baseado em grafos sobre as opções de tradução dessa lista para ao final, alcançarmos uma tradução.



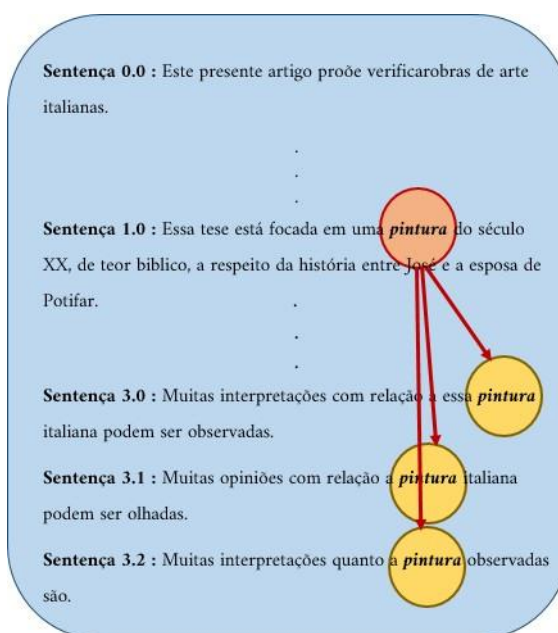
tradução são pontuadas acumulativamente, conforme as relações de cosseno. Observando a Figura 17, página 48, mostramos a identificação das classes gramaticais de cada palavra de uma sentença por meio da biblioteca SpaCy.

Figura 17 – Desmonstrativo de como identificamos as classes gramaticais das palavras em uma sentença com biblioteca spaCy. Observe que, em baixo de cada uma das palavras que compõe a sentença em questão, estão as classificações gramaticais disposta em inglês e de forma abreviada. Destacamos VERB como verbo, ADP como adjetivo e NOUN como substântivo, já que trabalhamos apenas com essas classes gramaticais.



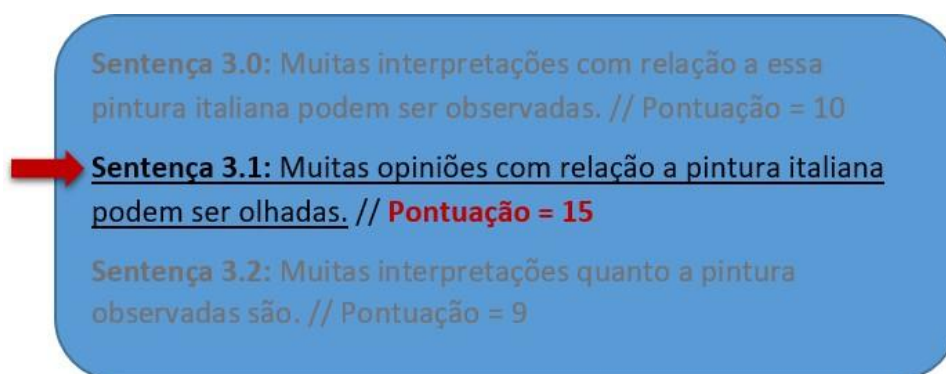
Em seguida, utilizando uma lista NBest de nosso experimento, mostramos na Figura 18 (pág.49) como é feita a comparação de palavras pertencentes a mesma classe gramatical, vinculadas a opções de tradução diferentes, atreladas a sentenças distintas por meio da nossa técnica de grafos.

Figura 18 – Comparando, por meio da nossa técnica de grafos, palavras de mesma classe gramatical e que pertencem a opções de tradução vinculadas a sentenças distintas. No exemplo, o substantivo pintura presente na tradução 0 referente a sentença 1, é comparado com as também palavras pintura vinculadas as três opções de tradução da sentença 3.



Ao final, selecionamos apenas uma opção de tradução por sentença, de acordo com sua pontuação como na Figura 19, pagina 49.

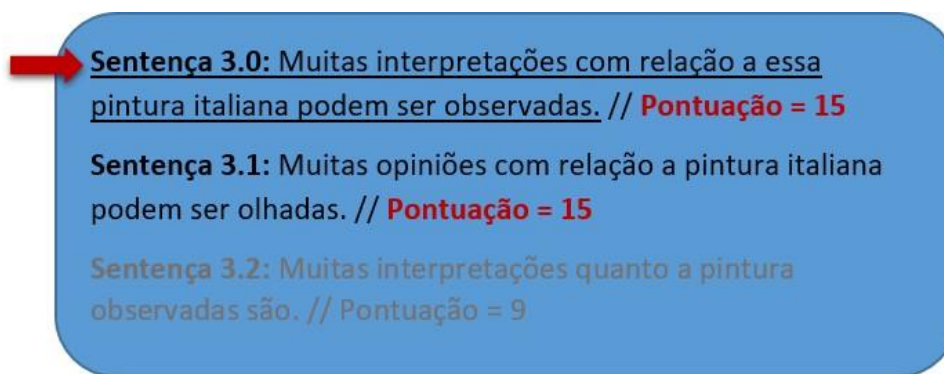
Figura 19 – Exemplo de pontuação referente as opções de tradução ilustradas na Figura 18 (pág.49). Conforme nossa técnica de grafos, a opção de tradução 1 referênte a sentença 3 é a que melhor pontuou em detrimento as opções 0 e 1 e portanto, ela é a tradução selecionada para representar a sentença em questão.



Em caso de empate entre as opções de tradução pertencentes a uma mesma

sentença, a melhor classificada conforme a lista NBset é a que será selecionada assim como na ilustração 20, página 50.

Figura 20 – Exemplo de quando as opções de tradução empatam na pontuação. Como podemos verificar, a opção 0 é selecionada pela nossa técnica para representar a sentença 3 porque ela vem primeiro na Lista NBest em detrimento a opção 1 da mesma sentença.



Apesar do conceito que empregamos ser relativamente simples, ele exige um trabalho de identificação muito bem elaborado. Pois, através do relacionamento entre palavras, buscamos identificar a opção de tradução que melhor represente sua respectiva sentença, conforme a relação semântica entre frases. Para dessa forma, produzimos traduções de textos mais coerentes. Na busca por uma solução, encontramos nas estruturas de dados conhecidas como listas e dicionários o meio pelo qual conseguimos identificar cada sentença, opção de tradução e palavras conforme os vínculos existente entre elas. Na Figura 21, página 51 ilustramos o que pretendemos fazer.

### 3.8.1 Utilizando as Estruturas de Dados

A lista é considerada por alguns como a mãe de todas as estruturas e basicamente é definida como uma sequência finita de elementos que podem ser iguais ou diferentes. A identificação de cada um desses elementos costuma ser automática, conforme são inseridos na lista que é definida por um par de colchetes (PYTHON.ORG, 2020).

Quando formos transferir as opções de tradução da NBest para a estrutura de dados lista, precisamos realizar isso sequencialmente, pegando uma por vez conforme a ordem que elas ocupam no documento gerado pelo Moses. Utilizando um objeto do tipo doc durante o processo, conseguimos transformar automaticamente cada opção de tradução em uma lista antes mesmo de inserirmos na lista que criamos. Significando que cada palavra em sua opção de tradução passa ser tratada individualmente. Quando transferimos uma opção de tradução para a lista desenvolvida, nós inserimos uma lista dentro da outra, de forma que a identificação de cada palavra fica atrelada a sua respectiva opção de tradução. Isso fica mais claro quando observamos a Figura 22 (pág.51).

Figura 21 – Separando as opções de tradução e as palavras que as compõem mediante as sentenças que elas representam. Aqui, vemos três quadros referente a sentenças e em cada um deles, temos suas respectivas opções de tradução separadas em linhas cuja as palavras que as compõem, são identificadas individualmente mediante retângulos ou quadrados.

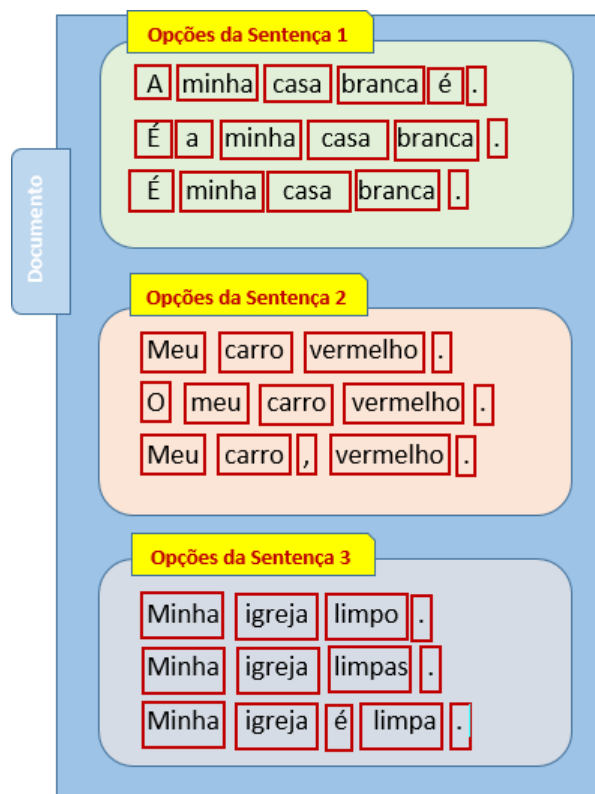
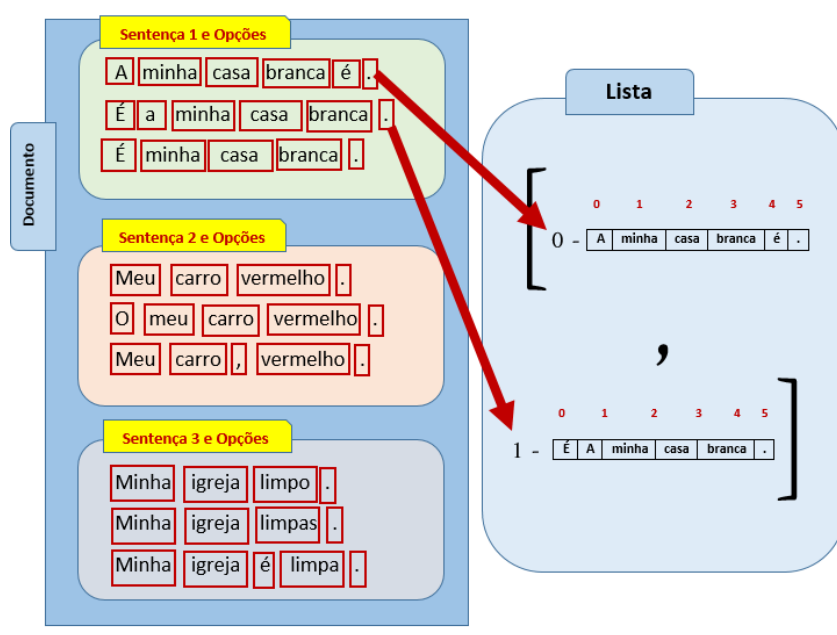


Figura 22 – Exemplo de transferência das opções de tradução para uma Lista.



Dando prosseguimento ao processo, utilizamos dicionários que costumam ser de-

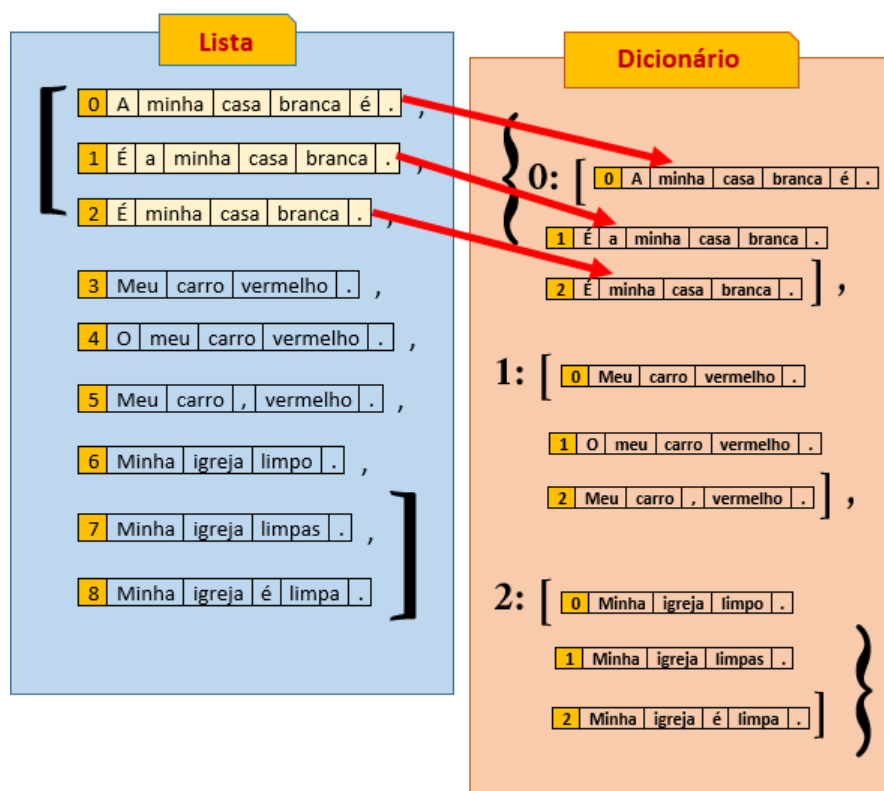
finalizados por um par de {} (USP - PANDA CURSO DE COMPUTAÇÃO, 2020) como na linguagem de programação Python.

As principais operações realizadas com esse tipo de estrutura consiste em recuperação de informações e armazenamento, a partir das chaves associativas (keys). Essas chaves associativas devem ser únicas e de um tipo qualquer (string ou numérica, por exemplo), desde que seja imutável. Essa chave associativa ou de acesso deve, por definição, ser separada de seu conteúdo pelo caractere dois pontos (:) (PYTHON.ORG, 2020). Assim, ao também optarmos pelos dicionários, conseguimos o que desejamos.

Criamos então um dicionário composto por um número  $x$  de chaves associativas enumeradas sequencialmente. Cada uma delas está associada a uma sentença que compõe o texto em questão e portanto, são exclusivas. Dessa forma, ao trabalharmos com uma tradução de texto composto por sete sentenças, sete *keys* (chaves) serão criadas e automaticamente enumeradas de 0 a 6.

Para cada key, nós inserimos as três opções de tradução correspondentes armazenadas e classificadas na lista (gravadas sequencialmente). Para a primeira key, as opções de tradução 0, 1 e 2 são associadas a ela e assim sucessivamente. Logo mais, na Figura 23 - página 52, a ilustração do processo.

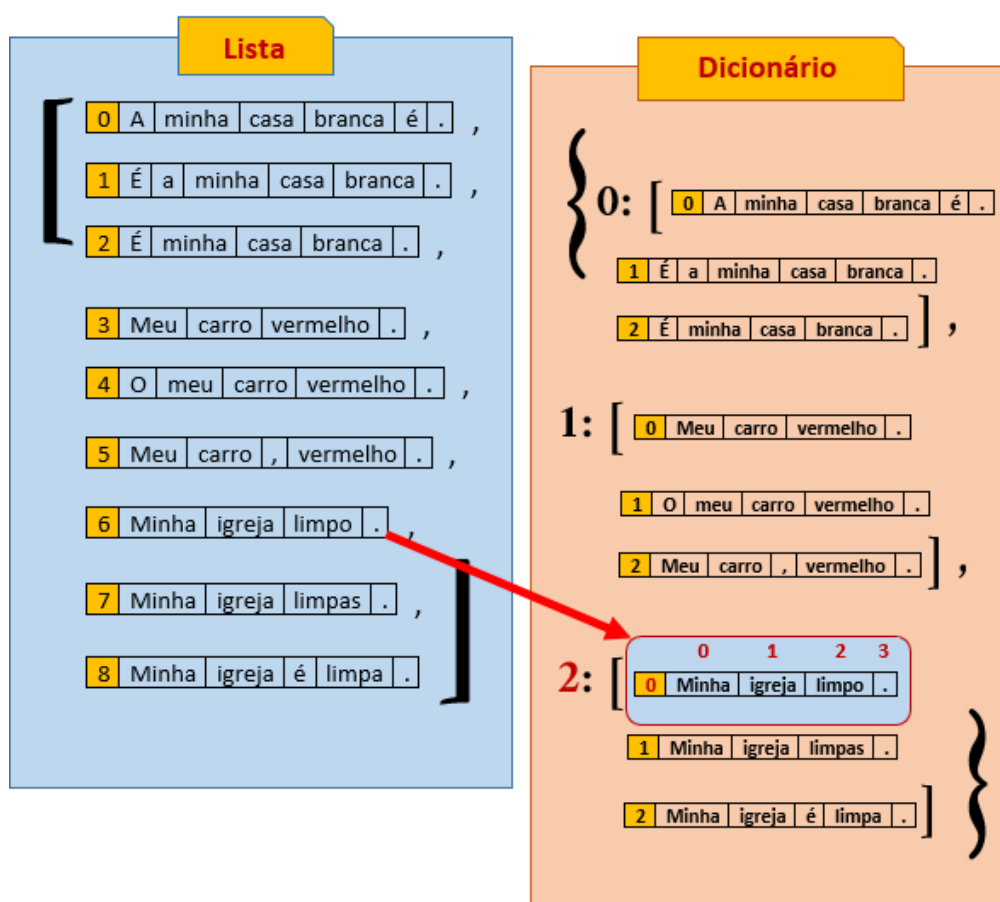
Figura 23 – Transferindo as opções de tradução e suas respectivas palavras de uma Lista para um Dicionário.



Quando inserimos em nosso dicionário, as opções de tradução sequenciais, em

blocos de três em três, associadas a uma key exclusiva e que indica a sentença a qual elas pertencem, também conseguimos identificar individualmente cada palavra (termo) contidos em cada opção de tradução e portanto, seleccioná-las quando necessário. Consequentemente, nós alcançamos o seguinte resultado, expresso na Figura 24, página 53:

Figura 24 – Reconhecendo sentenças, opções de tradução e palavras por meio de um dicionário. Para exemplificar, descatamos a sentença 2 (numeral em frente a um colchete), a opção de tradução 0 (em amarelo) e a identificação de cada uma das palavras que a compõe mediante uma numeração vermelha (acima da tradução).



Onde a palavra 1, pertencente a opção de tradução 0, vinculada a sentença 2 é identificada como:

**IGREJA**

, conforme ilustrado na Figura 24 (pág.53).

Partindo dessa técnica construímos nossos grafos, que facilitaram a identificação das melhores opções de tradução. Contribuindo para a elaboração de traduções mais coerentes, isso comparadas as emitidas pelo Moses.

Suponhamos que temos o seguinte texto em inglês na Tabela 6, página 54 que é submetido ao tradutor Moses.

Tabela 6 – Pequeno texto em Inglês composto por 4 sentenças.

Nome	Sentenças
S1	My car is blue.
S2	It is a complete vehicle.
S3	It is a new and very big car.
S4	My car is unique.

Sua lista NBest com as três melhores traduções para cada sentença fica exatamente como ilustrado na Tabela 7 (pág. 54).

Tabela 7 – Lista NBest com 3 opções de tradução por sentença. Referente ao texto na Tabela 6, página 54.

Sentenças	Opções de Tradução
S1	O meu carro é azul. É meu carro azul. É meu carro , azul.
S2	Trata se de um veículo completa. Trata se de um veículo total. Trata se de um veículo completo.
S3	Trata se de um novo e muito grande carro. Trata se de um novo e muito grande carro. É um novo e muito grande carro.
S4	O meu carro é única. O meu carro é único. O meu carro , é única.

Em seguida, mediante nosso método, construímos quatro grafos de coerência com a biblioteca NetworkX (NETWORKX, 2020) do Python (SILVA, 2018). Um especificamente para substantivos, outro para os adjetivos e ainda outro para os verbos e por último o grafo principal, resultante da somatória dos três primeiros. Todos concebidos com aresta direcionais, conforme a ordem textual das sentenças envolvidas. Onde o primeiro vértice (palavra ou entidade) pertença a uma opção de tradução, vinculada a uma sentença que antecede a sentença do segundo vértice e sua correspondente opção de tradução. Dessa forma, ilustramos o sentido do texto e o desenvolvimento do assunto, semelhante o que Parveen, Mesgar e Strube (2016) realizaram. Logo mais, mostramos em sequencia os grafos correspondentes aos substântivos (Figura 25, pág. 55), adjetivos (Figrua 26, pág. 55) e verbos (Figura 27, página 56) tendo como base a Lista NBest ilustrada na Tabela 8 (pág. 57). Ao final, na Figura 28 (pág. 56), exibimos nosso grafo principal que é resultante da somatória dos três grafos anteriores.

Para melhor compreensão e finalizar esse tópico, na Tabela 8 (pág. 57) exibimos a comparação da tradução segundo nosso modelo de coerência com a gerada pelo Moses.

Figura 25 – Grafo construído apenas por meio de substantivos (referente ao texto na Tabela 7, página 54).

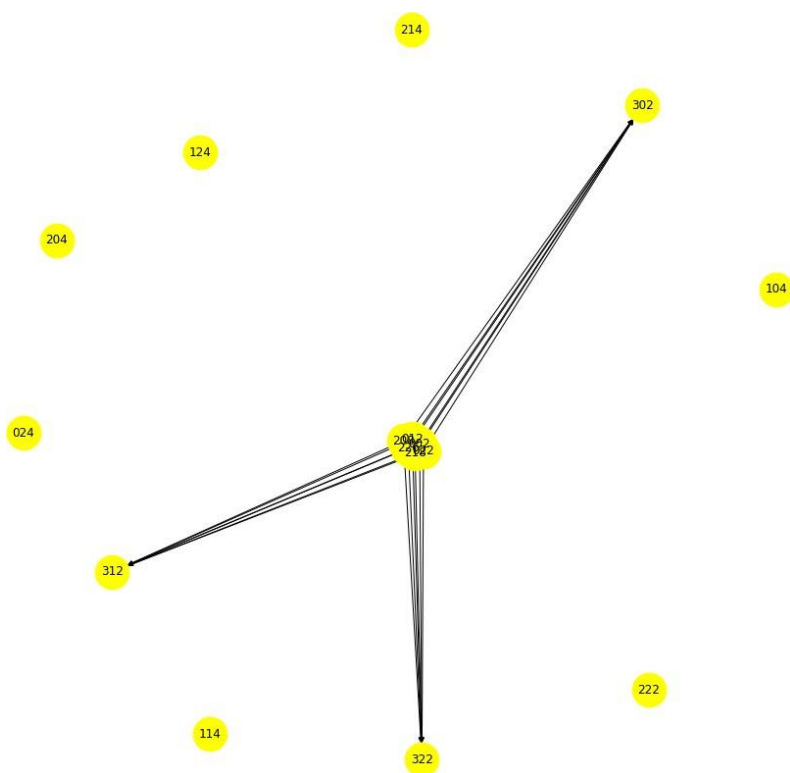


Figura 26 – Grafo construído apenas por meio de adjetivos (referente ao texto na Tabela 7, página 54).






Figura 27 – Grafo construído apenas por meio de substantivos (referente ao texto na Tabela 7, página 54).




Figura 28 – Grafo construído apenas por meio de adjetivos (referente ao texto na Tabela 7, página 54).




Tabela 8 – Comparando a tradução produzida pelo nosso modelo com a emitida pelo Moses. Podemos perceber que, para a terceira sentença, nosso modelo selecionou um opção de tradução diferente da que o Moses escolheu.

<b>Nossa Técnica</b>	<b>Moses</b>
O meu carro é azul.	O meu carro é azul .
Trata se de um veículo completa.	Trata se de um veículo completa.
<b>É um novo e muito grande carro.</b>	<b>Trata se de um novo e muito grande carro.</b>
O meu carro é única.	O meu carro é única .

## 3.9 Avaliando os Resultados

O ato de avaliar algo, implica em estimar o valor ou aferir algum tipo de qualidade a um determinado trabalho. No princípio, havia a ideologia de que peritos humanos deveriam avaliar o que era produzido pela tradução automática. Mas algumas características peculiares nessa forma de avaliação dificultaram o alcance de um padrão avaliativo. Uma delas é resultante da subjetividade do processo de tradução, que cada tradutor humano pode ter. Por isso, havendo a necessidade de uma avaliação quantitativa para a tradução automática, métricas computacionais foram criadas. Essas métricas propõe avaliar a fidelidade e fluência de traduções geradas (RIBEIRO, 2006).

### 3.9.1 BLEU

O BLEU é uma das primeiras métricas a conseguir reivindicar uma alta correlação com os pareceres humanos quanto a tradução de textos. Ela atua individualmente sobre seguimentos de palavras (sentenças) comparando n-gramas com n-gramas entre a sentença emitida computacionalmente e a concebida por um ser humano. Em caso de palavras improváveis, o BLEU as desconsidera, aceitando apenas aquelas presentes na referencia. De forma que o resultado final de avaliação de cada sentença corresponde ao número de palavras corretas com relação a frase de referência. A seguir, um exemplo em inglês de como o BLEU encontra a média aritmética baseada em unigrams (PAPINENI et al., 2002).

1. Candidato: the , the, the, the, the, the, the.
2. Referência1: The cat is on the mat.
3. Referência2: There is a cat on the mat.

Pode-se observar que 7 é o número de palavras da frase candidata. Quando comparada com a primeira referência, apenas duas palavras da frase candidata são localizadas na sentença. Na referencia 2, apenas um termo é estimado em toda a frase

contraposta. Dessa forma, o BLEU considera somente a primeira opção, cuja duas palavras foram encontradas.

### 3.9.2 Meteor

Semelhantemente, o Meteor também é uma métrica de avaliação de saída de máquina de tradução. Ele surgiu propositalmente a fim de superar possíveis fraquezas observadas na métrica BLEU (DOBRE, 2015).

O Meteor, a princípio, realiza um cálculo de pontuação observando palavra-a-palavra (unigrama), tendo como unidade básica de avaliação a frase. Para que ele possa fazer isso com exatidão, ele utiliza uma sequência de módulos de mapeamento de palavras. Esses módulos possibilitam com que cada palavra candidata seja alinhada com sua respectiva palavra na frase de referência. Desde que sejam no mínimo sinônimos entre si (LAVIE; DENKOWSKI, 2009).

## 3.10 Resumo do Capítulo

Vimos nesse capítulo como a máquina de tradução Moses funciona e como uma de suas funções (NBest) foi útil ao ser empregada em nosso trabalho. Por meio dela conseguimos diversas opções de tradução para cada uma das sentenças dos textos, assim conseguimos trabalhar com padrões de coerência. Esses padrões nos permitiram construir grafos mais relevantes quanto a modelagem da coerência textual.

Mostramos também como produzimos nosso modelo, que é diferente do elaborado por Born e co-autores (BORN; MESGAR; STRUBE, 2017). Detalhamos sua criação de forma didática e exemplificada, sendo possível visualizar com clareza cada uma das etapas.

---

# Experimentos

Nesse capítulo mostraremos como realizamos nossos experimentos. Começando pela apresentação das configurações do computador que utilizamos na validação de nosso modelo de coerência baseado em grafos.

Comentaremos também quais corpus paralelos usamos e como os configuramos para o treinamento do Moses. Explicaremos a forma pela qual optamos em treinar a máquina de tradução de forma que conseguimos resultados melhores.

Apresentaremos brevemente quais softwares empregamos para a construção de nosso modelo e quais textos utilizamos nos testes. Mostraremos igualmente como enviamos esses textos para o Moses e como recebemos as correspondentes listas NBest.

Para finalizar, descreveremos nossos quatro experimentos. Cada um de forma objetiva e clara para que o leitor os compreenda com facilidade.

## 4.1 Configurações do Equipamento

Nas últimas décadas, o avanço tecnológico dos computadores contribuiu significativamente para melhorias dos experimentos científicos. Que o diga o campo da tradução automática que, desde a década de 80, vem experimentando grandes avanços (MARTINS; NUNES, 2005).

Para nosso trabalho, dispusemos de um computador portátil configurado com um processador Core i7 8565U da Intel (LENOVO, 2020) pertence a oitava geração, com uma velocidade que alterna entre 1,8 a 4,6 GHz de processamento. Também contamos com dois pentes de memória do tipo DDR4 com velocidade máxima de 2400 MHz cada um que juntos, somam 12 GB de capacidade operante. Para o armazenamento, dispomos de um SSD de 250 Gbytes, com conexão M.2 e interface lógica NVMe (Non-Volatile Memory Express). Cujas velocidades para leitura equivale a 1700 MB/s e para gravações, 1300 MB/s (WESTERN DIGITAL, 2020). Nele, gravamos o sistema operacional Ubuntu Linux, versão 18.04.4 LTS

(UBUNTU LINUX, 2020) sobre o qual instalamos nossa máquina de tradução e também desenvolvemos nossa técnica utilizando o IDE (ambiente de desenvolvimento integrado) conhecida como Spyder, pertencente a plataforma Anaconda (ANACONDA, 2020).

Esses equipamentos de hardware e softwares relativamente novos, nos proporcionaram um cenário relativamente tranquilo para trabalharmos com grande quantidade de dados de forma veloz, econômica e rápida. Sendo suficientes para nossos experimentos.

## 4.2 Corpora de Treinamento para a Máquina de Tradução

Toda máquina estatística de tradução assim como o Moses, precisa ser treinada com um grande número de textos paralelos. Eles devem estar devidamente alinhados, sentença com sentença de forma que uma tenha o mesmo significado do que a outra (LOPEZ, 2008).

Para o treinamento da nossa máquina, os corpus paralelos estão em Português- Inglês. Corpus apenas em Português para os modelos de linguagem e em Português-Inglês para nossos modelos de tradução.

O conjunto de corpus paralelos que adquirimos é constituído por textos que não se repetem e que juntos, abordam uma variedade de temas. Eles foram obtidos gratuitamente de quatro sites que mencionamos a seguir:

- Corpus do Núcleo Interdisciplinar de Linguística Computacional, NILC<sup>1</sup>;
- Corpus do próprio portal do sistema de tradução Moses<sup>2</sup>;
- Projeto *the Open Parallel Corpus*, OPUS<sup>3</sup>; além do
- Corpus do projeto acadêmico da equipe da UFRGS liderada por Karin Becker que reúne diversos textos do SciELO (SOARES; MOREIRA; BECKER, 2019).

Optamos em treinar o Moses da forma mais completa e para isso, realizamos modificações nos corpus paralelos que adquirimos. Para aqueles considerados pequenos demais e que abordavam temas semelhantes, nós os juntamos em um único corpus. Os considerados muito grandes ou que apresentavam um tema exclusivo, dividimos em corpus menores. Sempre levando em consideração o alinhamento entre sentenças em cada um desses procedimentos.

<sup>1</sup> <<http://www.nilc.icmc.usp.br/nilc/tools/Fapesp%20Corpora.htm>>

<sup>2</sup> <<http://www.statmt.org/europarl/>>

<sup>3</sup> <<http://opus.nlpl.eu/>>

Todos os corpus que mantivemos intactos quanto os que modificamos, foram pré-formatados para estarem escritos apenas em letras minúsculas para melhor performasse da máquina de tradução, conforme detectado por Caseli e Nunes (2009b). Além disso, todos esses corpus receberam novos nomes por motivos meramente organizacionais. Visando facilitar nosso trabalho na hora de treinarmos o Moses. Na Tabela 9 (pág. 61) pode ser visto a relação dos corpus que utilizamos, já modificados por nós.

Tabela 9 – Relação dos Corpus Paralelos que nós utilizamos no Treinamento da nossa Máquina de Tradução. Nessa tabela, temos os nomes de cada corporea, o número de linhas de compõe cada um deles e a quantidade de palavras (tokens) em inglês e português presentes em sua composição.

Nome	Linhas	Tokens(PT)	Tokens(EN)
alcorao1	61.578	1.010.370	1.203.076
alcorao11	30.796	488.509	570.697
alcorao111	30.789	484.130	613.612
biblia1	37.305	852.248	937.789
biblia11	12.435	282.319	313.839
biblia111	12.435	279.014	306.880
capesp1	255.914	7.328.323	7.100.099
ciencia	155.995	2.532.677	2.695.422
europarl	1.960.407	50.328.236	49.554.741
fapesp1	1.375	30.025	33.473
fapesp2	1.608	31.928	33.529
fapesp3	156.712	3.467.951	3.739.509
fapesp4	1.314	28.133	30.541
fapesp5	1.447	30.951	32.731
fapesp6	160.975	3.566.178	3.842.532
globalvoice1	35.684	768.023	752.295
globalvoice11	17.842	363.595	367.202
globalvoice11	17.842	356.961	356.635
jornal	166.719	3.687.215	3.972.806
<b>TOTAL</b>	<b>3.119.172</b>	<b>75.917.039</b>	<b>76.456.708</b>

### 4.3 Treinando a Máquina de Tradução Moses

O treinamento completo do Moses envolve basicamente quatro etapas e três corpus de treinamento. Um corpus para a criação do modelo de linguagem e de tradução, outro para a etapa tunning ou seja, de calibração e mais um corpus para a etapa de avaliação.

A realização do treinamento é relativamente simples e pode ser efetuada de duas formas. A primeira e mais demorada é manual, por meio do qual o usuário deve informar

uma linha de comando por vez ao sistema. O segundo é mais eficiente, ocorre automaticamente por meio de um arquivo onde as linhas de comandos estão reunidos e são executadas pelo Sistema de Gerenciamento de Experimento (EMS) do Moses (KOEHN, 2005).

Como trabalhamos com um conjunto grande de dados, optamos treinar nossa máquina utilizando o EMS. Sendo necessário a cada treinamento, configurarmos apenas alguns detalhes em nosso arquivo como, relacionar caminhos de arquivos, pastas e corpus paralelos. Ao todo, 27 corpora foram usados em 9 treinamentos, nos proporcionando 18 modelos, ou seja, 9 modelos de linguagem e 9 de tradução.

## 4.4 O que Utilizamos para construir nosso Modelo de Coerência

Dentre inúmeras linguagens de programação disponíveis no mercado, nós optamos em trabalhar com o Python para a partir dele, construirmos nosso modelo de coerência. Fizemos essa escolha porque ela é uma linguagem de programação muito simples, robusta, eficaz, democrática e fácil de lidar (SILVA, 2018).

Para manipularmos o conteúdo textual de nossos documentos, nós escolhemos trabalhar com a biblioteca spaCy (SPACY, 2020). Por meio dela, utilizando um modelo de linguagem para o português, conseguimos realizar as principais tarefas que envolvem nossa aplicação como: formatar textos, identificar sentenças e termos e selecionar palavras conforme sua classe gramatical.

Decidimos trabalhar com o GloVe (PENNINGTON; SOCHER; MANNING, 2014) assim como Born e co-autores (BORN; MESGAR; STRUBE, 2017) e portanto, utilizamos um modelo de 300 dimensões. Ele foi treinado com 1.395.926.282 tokens em Português e está disponível em um dos sites do NILC (Núcleo Interinstitucional de Linguística Computacional) (NILC, 2020).

Por último, empregamos a biblioteca NetworkX (NETWORKX, 2020) para construirmos nossos grafos. Ela é muito popular pois apresenta uma interface de programação e implementação excelentes quando se trata de estudos envolvendo redes complexas.

## 4.5 Utilizando o Moses em Nosso Experimento

### 4.5.1 Como Servidor

Para enviarmos e recebermos automaticamente documentos do Moses, foi preciso utilizarmos a biblioteca XML-RPC. Com ela, conseguimos transformar nossa máquina de tradução em um servidor com o qual nossa aplicação estabeleceu uma conexão.

Utilizando o protocolo de comunicação HTTP, enviamos ao servidor Moses textos em inglês para, receber de volta as listas NBest para dessa forma, darmos prosseguimento aos nossos experimentos. Abaixo, mostramos o comando de ativação do Moses como um servidor:

```
/mosesdecoder/bin/mosesserver -f /working/mert-work/moses.ini
```

Logo em seguir, as configurações realizadas em nossa aplicação escrita em Python (SILVA, 2018).

```
http://host:port/RPC
```

Onde “*host*” é referente ao endereço IP e “*port*” é a porta de comunicação com o servidor (sendo 8080 o padrão) e “*RPC*” uma escrita padrão.

### 4.5.2 Arquivo Moses.ini

O decodificador Moses gera arquivos de configuração moses.ini ao final de cada treinamento. Por meio deles, o decodificador da máquina recebe diretrizes de como deve trabalhar durante o processo de tradução. Assim, como treinamos nove vezes nossa máquina de tradução, nove arquivos do tipo moses.ini foram criados conforme a Tabela 10 na página 64.

Em cada um deles, um modelo de linguagem e de tradução foram relacionados e calibrados automaticamente pela máquina de tradução. Com isso, o decodificador da máquina sabe o quanto utilizar do modelo de linguagem e do modelo de tradução, durante o processo de tradução.

Para uma performance de tradução melhor, o Moses permite que a calibragem entre os modelos seja alterada. Assim, na busca dos custos ideais para a dupla de modelos, realizamos diversos testes até encontramos a melhor calibragem para cada arquivo moses.ini. Os quais foram utilizados individualmente na tradução de cada texto que empregamos em nossos experimentos.



Tabela 10 – Na primeira coluna temos os nomes de cada arquivo moses.ini. Em seguida, apresentamos os corpus utilizados na elaboração do modelo de tradução (MT) e modelo de linguagem (ML). Na sequência, mostramos os corpus empregados na calibragem (tunning) da relação entre MT e ML durante o processo tradutório. Por fim, apresentamos as corporeas avaliativas, utilizadas para qualificar as traduções conforme os arquivos moses.ini.

<b>moses.ini</b>	<b>MT e ML</b>	<b>tunning</b>	<b>avaliação</b>
1	fapesp3	fapesp1	fapesp2
2	fapesp6	fapesp4	fapesp5
3	jornal	fapesp1	fapesp2
4	europarl	fapesp4	fapesp5
5	globalvoice1	globalvoice11	globalvoice111
6	biblia	biblia11	biblia111
7	capesp1	fapesp2	fapesp4
8	alcorao111	alcorao11	alcorao111
9	ciencia	fapesp2	fapesp1

## 4.6 Experimentos

Realizamos quatro experimentos distintos e verificamos a eficiência de nosso modelo de coerência por meio das métricas Meteor e BLEU (PAPINENI et al., 2002). Também qualificamos as traduções emitidas por nossa técnica e as traduções emitidas por outras máquinas de tradução. Em seguida, comparamos os resultados e verificamos o rendimento do nosso modelo.

### 4.6.1 Corpus de testes

Em cada um dos experimentos, utilizamos 43 textos paralelos Português-Ingês. Estes textos são resumos oficiais de dissertações de mestrado e teses de doutorado. Todos eles são constituídos de no mínimo três a no máximo dez sentenças. Com isso, dispensamos a utilização de subgrafos já que nossos textos são pequenos e portanto achamos o emprego da técnica desnecessária. A seguir, listamos os sites por meio dos quais obtivemos nossos textos:

- A biblioteca digital de teses e dissertações da USP<sup>4</sup>, responsável por disponibilizar conteúdos produzidos pela instituição e que atualmente, conta com mais de 90 mil documentos em seu banco de dados entre teses, dissertações e livre docência.
- O catálogo de teses e dissertações do CAPES<sup>5</sup>.

<sup>4</sup> <<https://www.teses.usp.br/>>

<sup>5</sup> <<https://catalogodeteses.capes.gov.br/catalogo-teses/#!/>>

- O repositório da produção científica e intelectual da UNICAMP<sup>6</sup> (Universidade Estadual de Campinas), que tem por objetivo facilitar o acesso a produções científicas produzidas pela Universidade. Uma iniciativa desenvolvida pela instituição, a qual busca por meio de padrões e protocolos de qualidade, compor um conjunto de esforços científicos nacionais e internacionais em prol da sociedade.
- A biblioteca digital brasileira de teses e dissertações BDTD<sup>7</sup>, que foi criada e é mantida pelo Instituto Brasileiro de Informação em Ciência e Tecnologia (IBICT). Um portal responsável por abrigar mais de 600 mil documentos científicos produzidos por diversas instituições brasileiras.

Logo mais, apresentamos a Tabela 11 (pág.66) com nossos 43 resumos, renomeados numericamente de 1 a 43, para facilitar seu manejo durante todo nosso experimento. Nessa tabela poderemos ver além dos nomes, a fonte, o tema abordado, a quantidade de sentenças de cada resumo, o número de palavras em português e a contagem dos termos para a versão inglês de cada um deles.

## 4.6.2 Experimento 1

Neste experimento, cada texto do corpus de teste foi submetido à máquina de tradução 9 vezes. A cada submissão o Moses emitiu uma tradução e uma lista NBest. A partir desses resultados, aplicamos o modelo de coerência proposto a estas listas NBest. Em seguida, aplicamos sobre elas e também sobre as traduções do Moses, as métricas de avaliação. Concluído o processo, comparamos nossas traduções com as traduções do Moses e verificamos a contribuição da abordagem proposta.

## 4.6.3 Experimento 2

O objetivo deste experimento foi o de verificar a influência do modelo de linguagem na tradução. Nesta etapa criamos um modelo de linguagem baseado em 14 corpora, sendo eles Bíblia1, Bíblia11, Bíblia111, Fapesp1, Fapesp2, Fapesp3, Fapesp4, Fapesp5, Fapesp6, Capes1, GlobalVoice1, GlobalVoice11, GlobalVoice111 e Ciência, mostrados na Tabela 9 (pág. 61). Ainda nesta etapa, selecionamos os 3 modelos de tradução mais bem avaliados no Experimento 1. A cada um deles, associamos nosso modelo de linguagem recém criado, alterando a referência no campo correspondente nos arquivos do tipo moses.ini. Em seguida, por 3 vezes, ou seja, para cada um dos 3 melhores modelos de tradução do Experimento 1, submetemos cada um dos 43 textos à máquina de tradução. Para

<sup>6</sup> <<http://repositorio.unicamp.br/>>

<sup>7</sup> <<http://bdttd.ibict.br/vufind/>>

Tabela 11 – Relação de Textos utilizados em nossos testes.

<b>Nome</b>	<b>Fonte</b>	<b>Tema</b>	<b>Linhas</b>	<b>Tokens(PT)</b>	<b>Tokens(EN)</b>
01	USP	Política	7	188	177
02	USP	Política	10	267	223
03	USP	Política	6	206	211
04	CAPES	Teológico	10	288	307
05	USP	Adm. Escolar	6	185	199
06	USP	Didática	7	193	175
07	USP	Política	7	141	137
08	USP	Computação	5	158	152
09	USP	Comunicação	3	57	65
10	USP	Comunicação	4	107	121
11	USP	Comunicação	5	87	103
12	USP	Cultura	6	174	180
13	BDTD	Informação	6	190	183
14	BDTD	Informação	5	169	170
15	BDTD	Informação	6	165	168
16	USP	Cultura	5	158	144
17	USP	Direito	3	74	81
18	USP	Direito	6	151	160
19	USP	Direito	6	167	178
20	BDTD	Filosofia	8	300	303
21	BDTD	Imigração Judaica	5	122	135
22	USP	Cultura Judaica	5	98	116
23	USP	Cultura Judaica	5	165	158
24	BDTD	Cultura Judaica	8	189	193
25	BDTD	Cultura Judaica	5	117	121
26	USP	Relaç. Inter.	6	159	162
27	CAPES	Economia	6	108	96
28	USP	Computação	7	193	187
29	USP	Computação	5	171	143
30	CAPES	Relaç. Inter.	6	172	176
31	CAPES	Cultura	8	201	200
32	UNICAMP	Transporte	10	376	370
33	UNICAMP	Arqueologia	3	117	108
34	UNICAMP	Arqueologia	6	234	247
35	UNICAMP	Bíblia	5	90	94
36	UNICAMP	Educação	6	126	138
37	UNICAMP	Biblioteca	5	137	136
38	UNICAMP	Biblioteca	7	231	252
39	UNICAMP	Ciência Médica	9	352	337
40	UNICAMP	Política	7	261	253
41	UNICAMP	Política	6	189	187
42	UNICAMP	Política	5	189	186
43	UNICAMP	Educação	8	350	353

cada texto o Moses emitiu uma tradução e uma lista NBest. A partir desses resultados, aplicamos o modelo de coerência proposto às listas NBest de cada texto. Em seguida, aplicamos as métricas de avaliação. Concluído o processo, comparamos nossas traduções com as traduções do Moses e assim, verificamos o quanto nossa técnica fez a diferença. Na Tabela 12 (pág. 67) podemos verificar o nome dos novos três arquivos do tipo moses.ini modificados com o modelo de linguagem que desenvolvemos denominado "geral".

Tabela 12 – Aqui expomos os três arquivos moses.ini que criamos para essa etapa de testes. Nessa tabela, também referenciamos os corpus utilizados na construção de cada Modelo de Tradução (MT). Além disso, mostramos o Modelo de Linguagem (ML) criado por nós e evocado pelos três moses.ini.

<b>moses.ini</b>	<b>MT</b>	<b>ML</b>
G5	globalvoice1	geral
G7	capex1	geral
G9	ciencia	geral

#### 4.6.4 Experimento 3

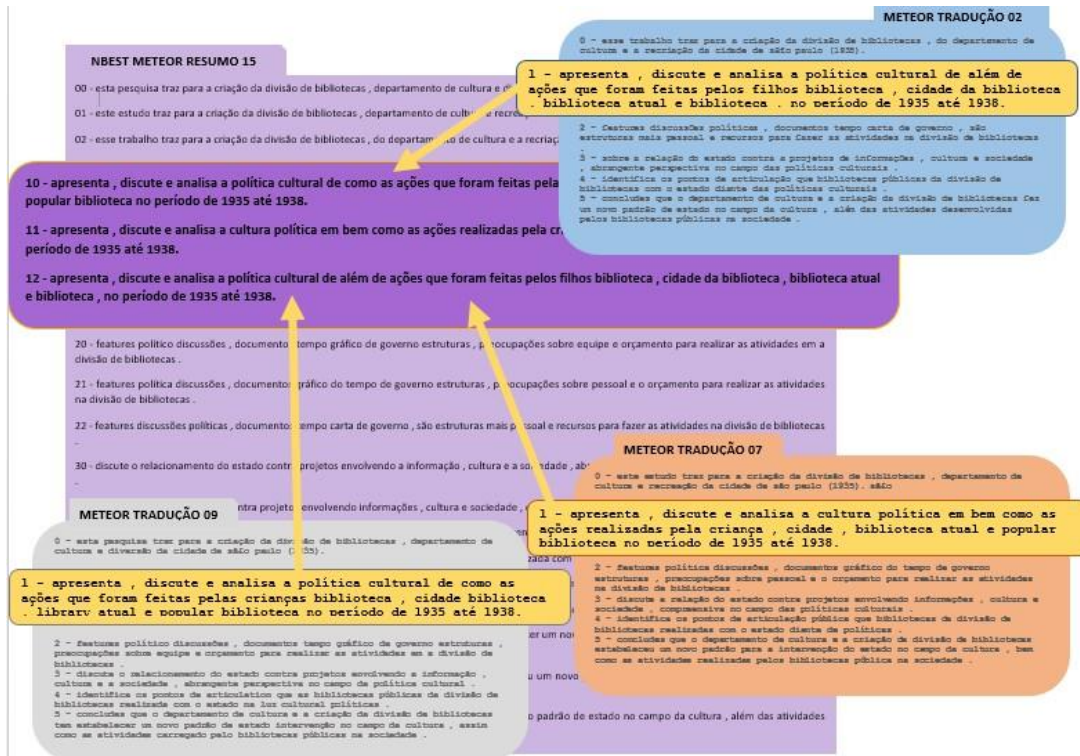
Nessa etapa não foi utilizada a máquina de tradução Moses diretamente. Em vez disso, reutilizamos alguns resultados obtidos nos experimentos anteriores. Selecionamos as 3 melhores traduções de cada texto segundo os melhores resultados das métricas de avaliação. Com essas traduções, criamos duas listas NBest para cada texto. Uma, segundo os três melhores resultados definidos pelo Meteor e, a outra, a partir das 3 melhores traduções conforme o BLEU. Sobre cada uma dessas listas, aplicamos nosso modelo de coerência. Como avaliação, estas listas foram separadas em dois grupos, conforme a influência que as métricas tiveram na criação das listas NBest que utilizamos. Assim, o Meteor avaliou apenas os resultados provenientes de nosso modelo de coerência, aplicados em listas NBest geradas a partir de traduções avaliadas somente por ele. Da mesma forma procedemos com relação os resultados quantificados pelo BLEU. Em seguida, comparamos os devidos resultados com os das etapas anteriores, respeitando a questão das métricas. Na Figura 29, página 68 podemos ver um desenho de como nossas listas NBes foram criadas nessa fase de experimentos.

#### 4.6.5 Experimento 4

Neste experimento nós comparamos os resultados obtidos no Experimento 3 com as traduções dos mesmos textos obtidas pelo Google Tradutor<sup>8</sup>.

<sup>8</sup> <<http://translate.google.com.br>>

Figura 29 – Construção de nossa lista NBest nessa terceira etapa a partir das três melhores traduções de um mesmo texto classificadas pelas métricas Meteor e BLEU nos experimentos anteriores. Em azul, cinza e laranja, mostramos as três melhores traduções com as quais criamos nossa lista NBest que está ilustrada na cor roxa. Em amarelo, destacamos apenas a sentença 1 para exemplificar o processo de elaboração da nossa lista.



## 4.7 Resumo do Capítulo

Nesse Capítulo apresentamos como realizamos nosso experimento, a começar pelas configurações do computador que utilizamos. Depois, mostramos os corpus paralelos em Inglês-Português que usamos no treinamento da nossa máquina de tradução. Descrevemos em seguida como treinamos o Moses e justificamos a escolha pelas ferramentas que empregamos para construir nosso modelo de coerência. Citamos como automatizamos o envio e recebimento de documentos por parte do Moses e de nossa aplicação para depois expormos os textos que empregamos em nossos testes que ao final, foram explicados um a um.

---

## Resultados e Discussões

Nesse capítulo explicaremos como empregamos cada uma das métricas de avaliação na qualificação de nosso modelo de coerência comparado com outras traduções.

Apresentaremos também os resultados alcançados em cada um dos quatro experimentos que propomos, descrevendo minuciosamente os resultados obtidos.

Concluiremos com uma breve discussão dos resultados. Comparando-os uns com os outros, para compreendermos melhor a capacidade de nosso modelo em produzir traduções mais coerentes.

### 5.1 Como Utilizamos as Métricas de Avaliação

Todo resumo de tese costuma ser apresentado em dois idiomas. Para nossos experimentos, utilizamos os escritos em Inglês para gerarmos traduções, com ou sem nossa técnica. E suas versões escritas em português, como referências para nossas métricas de avaliação.

Ambas as métricas foram empregadas da mesma forma em nossos experimentos, por meio das seguintes linhas de programação:

```
BLEUScore = nltk.translate.bleu_score.sentence_bleu([referencia], hipotese)
```

para o BLEU e

```
METEORscore = nltk.translate.meteor_score.single_meteor_score(hip, refer)
```

correspondente ao Meteor.

Para cada tradução, tanto o BLEU quanto o Meteor calcularam uma avaliação, comparando a hipótese (tradução) com a respectiva referência (resumo em português). Onde o valor 1, corresponde a uma tradução idêntica ao resumo e 0, a uma tradução descartável sem qualquer proveito. Portanto, quanto mais perto do 1, melhor é a tradução.

## 5.2 Resultados

Antes de iniciarmos a exposição dos resultados, salientamos que nem todas as solicitações de tradução enviadas ao Moses foram atendidas, tanto na primeira quanto na segunda parte de nossos experimentos.

O motivo para tal ocorrência é devido a incapacidade da máquina de tradução em lidar com caracteres diferentes, produzidos durante o processo de tradução. Ocasionalmente em um erro com o qual o Moses não consegue lidar e que nesse caso, nos privou de pouquíssimas traduções.

Para resolvermos esse problema de forma rápida, resolvemos ignorar a ausência dessas traduções registrando um "-" nos respectivos campos nas Tabelas onde as pontuações emitidas por cada métrica de avaliação são mostradas.

### 5.2.1 Experimento 1

Pudemos observar que, das 373 traduções emitidas pela nossa técnica, 124 (33,24%) proporcionaram traduções diferentes das suas concorrentes emitidas pelo Moses enquanto, 249 (66,76%) foram indiscutivelmente iguais às geradas pela máquina de tradução.

Das traduções distintas geradas pela nossa técnica, 61 foram identificadas pela métrica Meteor. Dentre elas, 29 contribuíram positivamente com uma melhora estimada de 1% em relação às traduções geradas pelo Moses. Isso equivale a 47,54% contra os 52,46% das traduções geradas pela nossa técnica que foram inferiores às produzidas pelo Moses e avaliadas pelo Meteor. Na Tabela 13 (pág. 84) e na Tabela 14 (pág. 85) podemos respectivamente observar as pontuações das traduções emitidas pelo Moses e as geradas a partir de nosso modelo de coerência, conforme a métrica Meteor.

Na métrica Bleu, 63 traduções produzidas pela técnica de grafos se distinguiram das emitidas pelo Moses. Desse montante, 25 contribuíram de forma positiva (cerca de 1%) quanto à qualidade das traduções em comparação às suas concorrentes. Apresentando também, uma porcentagem menor (39,68%) em relação aos 60,32% das que proporcionaram traduções inferiores às produzidas pela máquina de tradução Moses. Na Tabela 15 (pág. 86) podemos verificar as pontuações das traduções emitidas pelo Moses conforme a métrica BLEU. Agora, na Tabela 16 (pág. 87), estão as avaliações alcançadas pelas traduções segundo nossa técnica, qualificadas também pelo BLEU.

## 5.2.2 Experimento 2

Detectamos que das 128 traduções emitidas por nosso modelo de coerência, 32 (24,8%) traduções mostraram-se superiores quando comparadas com as emitidas pelo Moses. Dentre elas, 15,5% (20 traduções) foram detectadas pelo Meteor e 9,3% (12 traduções) pela métrica BLEU. Na Tabela 17, página 88 e na Tabela 18 (pág. 89) vemos os resultados avaliados segundo as duas métricas.

Para as 20 traduções superiores analisadas pelo Meteor, 1,45% foi a média de ganho que elas obtiveram sobre as produzidas pelo Moses enquanto que, 1% foi a contribuição proporcionada pelas 12 melhores traduções avaliadas pelo BLEU.

Verificamos que 23 (17,8%) traduções produzidas pela nossa técnica apresentaram qualidade inferior quando comparadas as proporcionadas pelo Moses, sendo que 10,9% (14 traduções) correspondem as traduções identificadas pelo Meteor e 6,9% (9 traduções) pelo BLEU. Em média, as testadas pelo Meteor apresentaram uma perda correspondente a 1,64%, contra 1% pelas apuradas pelo BLEU.

Ao compararmos os resultados dessa etapa com os da anterior, percebemos que houve um aumento proporcional de 17,46% de traduções melhores emitidas pela nossa técnica com relação as geradas pelo Moses.

Dos 3 arquivos moses.ini que desenvolvemos, o arquivo G5 foi o que mais contribuiu positivamente para nossa técnica de coerência. Ao todo, ele possibilitou 17 traduções avaliadas tanto pela métrica Meteor, quanto pelo Bleu. Dessas 17 traduções, 12 colaboraram positivamente com relação aos resultados finais contra 5 que pioraram os resultados quando comparados ao que o Moses emitiu.

Seguindo o arquivo G5, está o arquivo G7 com a mesma quantia de traduções com qualidade superior ou seja, 12. Apesar disso, esse arquivo moses.ini colaborou para o surgimento de 7 traduções classificadas inferiores se comparadas as que o Moses produziu. Por esse motivo, nós a colocamos em segundo lugar em nossa avaliação, mesmo que ela apresente duas traduções ao todo (19) a mais do que G5.

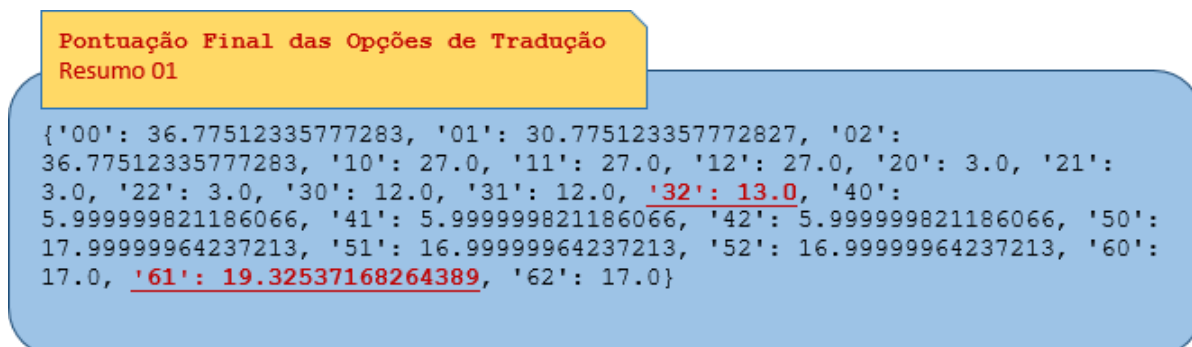
Por fim, temos o arquivo G9 que no total, também possibilitou 19 traduções produzidas por nossa técnica, assim como o G7. Mas, diferentemente de G5 e G7, desse total, apenas 8 traduções foram consideradas melhores do que suas concorrentes. Acabando que 11, foram traduções consideradas piores do que as produzidas pela nossa máquina de tradução.

Logo mais, produzida pelo moses.ini G5, podemos observar na Figura 30 (pág. 72) as pontuações obtidas por cada opção de tradução referente as sete sentenças pertencentes ao resumo 01.

A seguir, na Figura 31 (pág. 72) o grafo de tradução correspondente ao resumo 01




Figura 30 – Nessa ilustração, temos a identificação de cada opção de tradução do resumo 01 seguidas por suas respectivas pontuações alcançadas mediante nossa técnica de grafos.



conforme nossa técnica.

Figura 31 – Grafo correspondente as interações semânticas entre as opções de tradução, pertencentes a sentenças diferentes referente ao que foi ilustrado nas Figuras 30 (pág. 72) e 32 (pág. 73).



A seguir na Figura 32 (pág. 73), mostramos a interferência da nossa técnica de grafos e a pontuação que ela proporcionou as opções de tradução referente ao resumo 01. Como constatado na Figura 30 (pág. 72), vemos que conforme nosso algoritmo, a opção 2 da terceira sentença e a opção 1 da sexta foram consideradas melhores pois apresentaram maior conexão semântica em detrimento as suas concorrentes.

Figura 32 – A partir do que foi mostrado na Figura 30 (pág. 72) nós exemplificamos aqui a última etapa da construção da tradução do resumo 01 segundo nossa técnica. Destacamos duas opções de tradução que, de acordo com o Moses, não seriam as melhores traduções para suas respectivas sentenças mas que, segundo nossa técnica, foram consideradas melhores conforme a pontuação que elas obtiveram.

**Lista NBest**

00 - este trabalho tem o objetivo de identificar formas de uso e as contribuições de tecnologias de informação e comunicação (tics) a organização , a comunicação e a mobilização de organizações indígenas no brasil e a colômbia .

10 - as tentativas para identificar e apresentar estes casos de pesquisas através de entrevistas com os membros da coordenação das organizações indígenas da amazônia brasileira (coaiab) e a organização nacional indígena da colômbia (cnic) na perspectiva de uma antologia de dimensões escolhida .

20 - primeiro , o conceito de democracia e a importância de o papel do cidadão , em movimentos sociais poderá ser considerado .

21 - primeiro , o conceito de democracia e a importância de o papel do cidadão em movimentos sociais poderá ser considerado .

22 - primeiro , o conceito de democracia e a importância de o papel do cidadão , em movimentos sociais poderá ser considerado .

30 - this will be seguiu o papel das tic em a organização dos espaços democrática .

31 - this will be seguiu o papel das tic em a organização de espaços democrática .

**32 - this will be seguiu o papel das tic em a organização dos espaços democrático .**

40 - por isso , as tentativas para refletir sobre a sociedade de informação " " defendeu por castells (1999) .

50 - estas ideias , com base no contexto dos dois países e os seus movimentos indígenas , será discutido especificamente a estudos de caso sobre o uso de tics para fins organizacional e comunicação .

60 - este trabalho é justificada , porque vários movimentos indígenas na américa latina estão a usar de tic para a expressão cultural e de demonstração de resistência , a fim de proteger as suas comunidades .

**61 - este trabalho é justificada , porque vários movimentos indígenas na américa latina estão a usar de tic para a expressão e de demonstração de cultural , no intuito de resistência para proteger as suas comunidades .**

62 - este trabalho é justificada , porque vários movimentos indígenas na américa latina estão a usar de tic para a expressão e de demonstração de resistência culturalais , a fim de proteges as suas comunidades .

**Tradução Final**

00 - este trabalho tem o objetivo de identificar formas de uso e as contribuições de tecnologias de informação e comunicação (tics) a organização , a comunicação e a mobilização de organizações indígenas no brasil e a colômbia .

10 - as tentativas para identificar e apresentar estes casos de pesquisas através de entrevistas com os membros da coordenação das organizações indígenas da amazônia brasileira (coaiab) e a organização nacional indígena da colômbia (cnic) na perspectiva de uma antologia de dimensões escolhida .

20 - primeiro , o conceito de democracia e a importância de o papel do cidadão , em movimentos sociais poderá ser considerado .

**32 - this will be seguiu o papel das tic em a organização los espaços democrático .**

40 - por isso , as tentativas para refletir sobre a sociedade de informação " " defendeu por castells (1999) .

50 - estas ideias , com base no contexto dos dois países e os seus movimentos indígenas , será discutido especificamente a estudos de caso sobre o uso de tics para fins organizacional e comunicação .

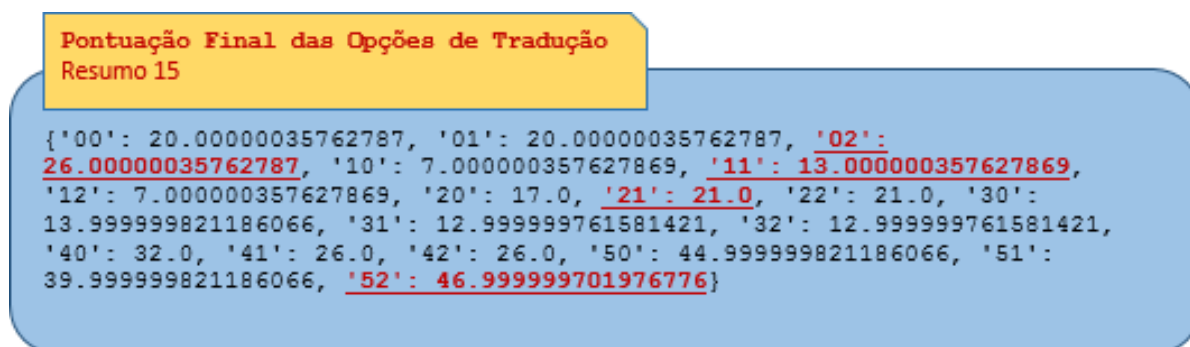
**61 - este trabalho é justificada , porque vários movimentos indígenas na américa latina estão a usar de tic para a expressão e de demonstração de cultural , no intuito de resistência para proteger as suas comunidades .**

### 5.2.3 Experimento 3

Nesse experimento produzimos cerca de 86 traduções proporcionadas por nosso modelo de coerência. Metade dessa quantia, foram avaliadas pela métrica Meteor enquanto a outra, pelo BLEU.

Das 43 traduções verificadas pelo Meteor, 38 (88,3%) superaram as melhores traduções produzidas nos Experimentos 1 (pág. 70) e 2 (pág. 71). Em média, esse ganho corresponde a 7,3% dentre o qual, 20% equivale ao pico alcançado. Logo mais na Figura 33 (pág. 74), a pontuação de cada opção de tradução correspondente ao resumo 15 conforme a métrica Meteor. Essa tradução foi considerada uma das melhores que alcançamos nessa etapa de testes quando comparamos com os resultados produzidos nos experimentos anteriores.

Figura 33 – Pontuação das opções de tradução referentes ao resumo 15, emitidas no Experimento 3 segundo nossa técnica de grafos.



Em seguida na Figura 34 (pág. 75), conforme a métrica Meteor, a comparação entre a melhor tradução presente nas etapas anteriores com a produzida nessa (também referente ao resumo 15).

Ilustrado na Figura 35 (pág. 76) o grafo correspondente a tradução alcançada e registrada na Figura 34.

Não muito diferente, as 43 traduções avaliadas pelo BLEU também se saíram bem. Dessas 43 traduções, 39 (90,7%) superaram as melhores traduções produzidas nos Experimentos 1 (pág. 70) e 2 (pág. 71). Em média, essa superação corresponde a 5,7% dentre o qual, 11% equivale ao pico alcançado.

Para exemplificar o quanto obtivemos de melhorias nas traduções, na Figura 36 (pág. 76) nós mostramos a pontuação das opções de tradução referente ao resumo 36. Esse resumo foi considerado o melhor dentre o produzidos nessa etapa conforme a métrica de avaliação BLEU.

Logo mais na Figura 37 (pág. 77), podemos verificar a comparação da tradução

Figura 34 – Comparando a melhor tradução emitida nas etapas 5.2.1 e 5.2.2 do resumo 15, com a tradução do mesmo texto gerada no Experimento 3.

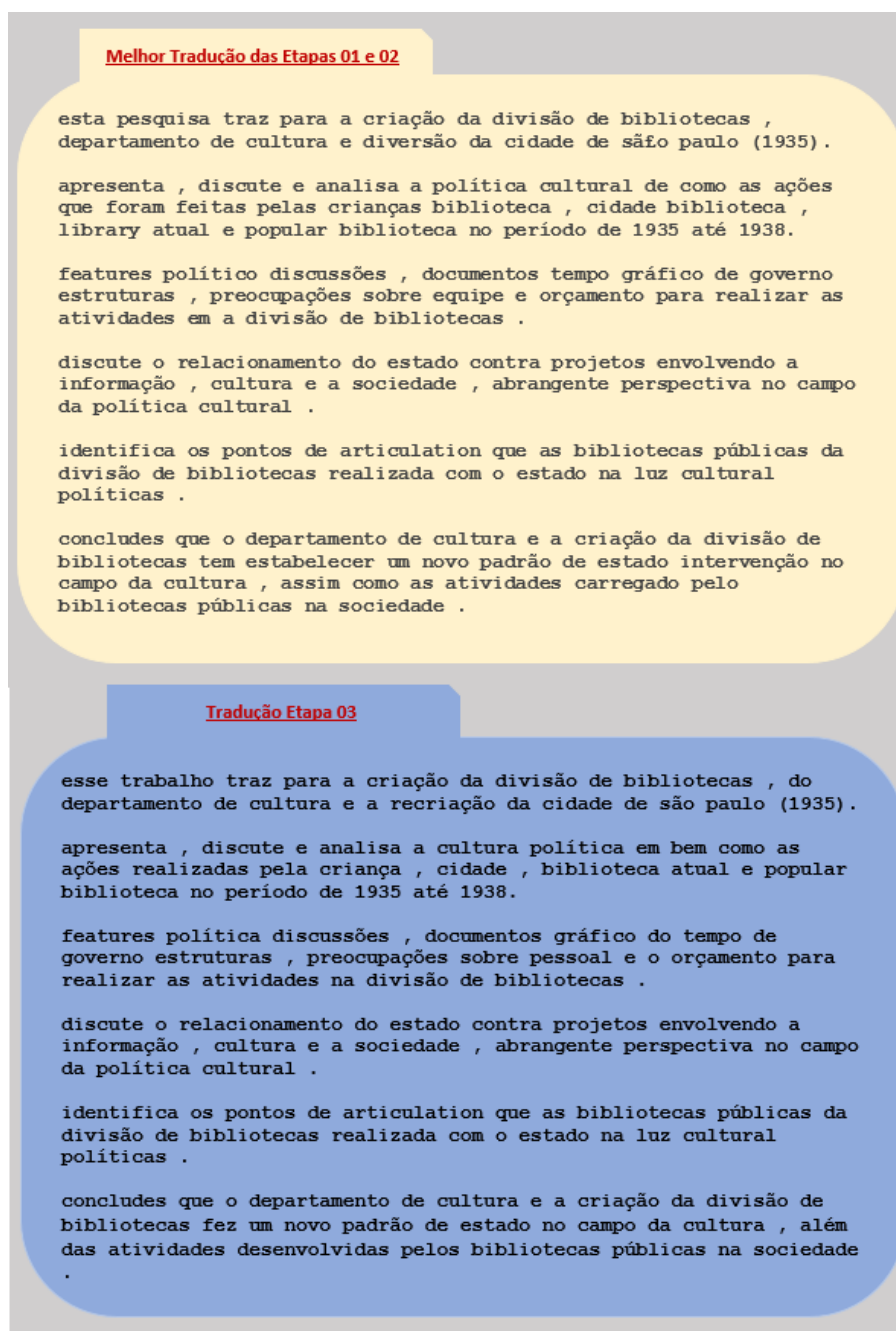


Figura 35 – Grafo referente a tradução emitida pela nossa técnica no Experimento 3 com relação ao resumo 15.


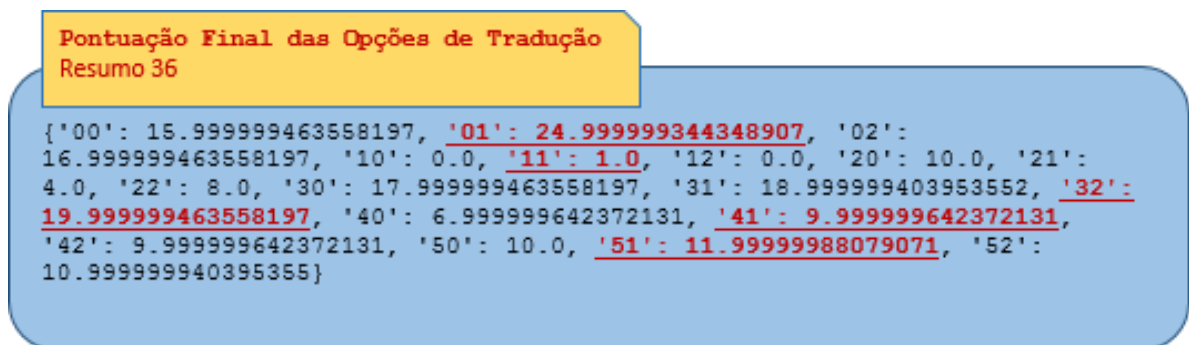


Figura 36 – Pontuação das opções de tradução referentes ao resumo 36, obtidas nesse Experimento 3.



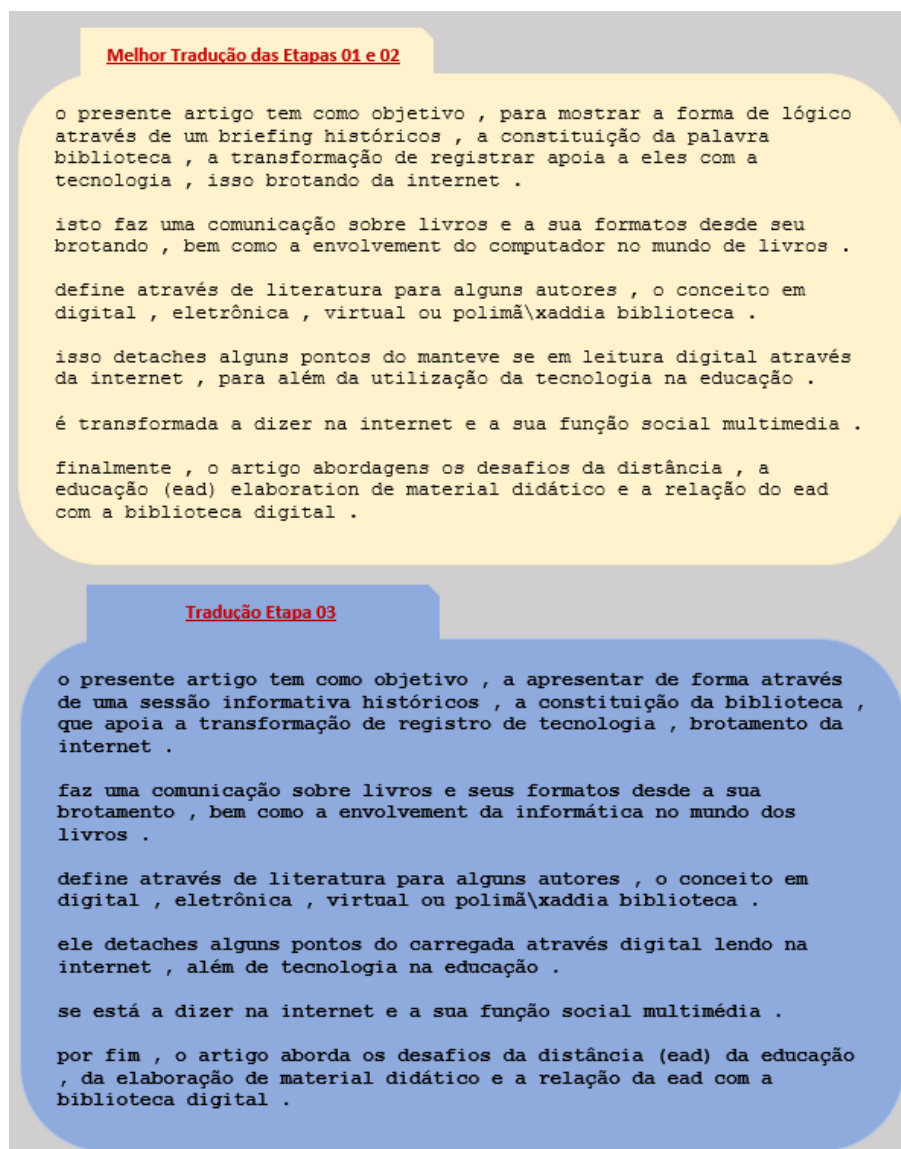
do resumo 36 alcançado nesse experimento com a melhor tradução desse mesmo texto produzido nas etapas anteriores.

A seguir, na Figura 38 (pág. 78) mostramos o grafo produzido pela nossa técnica referente ao resumo 36 nessa etapa de testes.

Nesse experimento, poucos foram os resultados negativos, dentre as 43 traduções



Figura 37 – Comparando a melhor tradução emitida nas etapas 1 (pág. 70) e 2 (pág. 71), referente ao resumo 36 com a tradução do mesmo texto gerada no experimento 3.



verificadas pelo Meteor, apenas 4 foram desfavorecidas quando comparadas com os melhores resultados produzidos nos Experimentos 1 e 2. Apresentando uma média correspondente a 4% dentre o qual o pico foi de 11%. Das 43 traduções qualificadas pelo BLEU, 3 produziram resultados negativos quando comparadas com as melhores traduções produzidas nas etapas 1 e 2. A inferioridade que elas apresentaram corresponde apenas ao valor médio de 1,66% dentro o qual, o pico equivale a 2%.

## 5.2.4 Experimento 4

Os textos de teste foram submetidos ao Google Tradutor e em seguida avaliados pelas métricas. Feito isso, comparamos esses resultados aos do experimento anterior. Na

Figura 38 – Grafo referente a tradução emitida pela nossa técnica com relação ao resumo 36 no Experimento 3.




Tabela 19 (pág. 90), podemos ver a comparação dos resultados dos Experimentos 3 e 4.

Observe que os textos escolhidos, e traduzidos segundo a técnica de coerência baseada em grafos, realçaram a diferença entre as métricas. Enquanto a métrica Meteor apresentou melhores resultados que o Google Tradutor nos textos 7, 11, 15, 17, 18, 21, 22, 27, 36, 38 e 43, a métrica BLEU mostrou melhores resultados nos textos 7, 15, 27, 30 e 37.

Ao compararmos as avaliações obtidas pelo Meteor em ambas as etapas, detectamos que 11 (26%), pertencentes ao Experimento 3, foram superiores as produzidas pelo Google Tradutor. Em média, a superioridade dessas traduções equivalem a 4%. Quanto aos resultados restantes, 4 (9%) deles se igualaram enquanto os outros 28 (65%) foram inferiores aos gerados pelo Google Tradutor. A seguir, na Figura 39 (pág. 79) referente ao resumo 36, vemos a comparação da melhor tradução produzida pelo nosso modelo contra a produzida pelo Google Tradutor e o resumo original.

Adiante nas Figuras 40 (pág. 80) e 41 (pág. 80), as pontuações de cada opção de tradução e o grafo gerado.

Agora, quando compararmos as avaliações obtidas pelo BLEU nos experimentos 3 e 4, verificamos que 5 (11,6%), pertencentes a etapa anterior, foram superiores as produzidas

Figura 39 – Comparando a tradução do resumo 36 obtido no Experimento 3, com a gerada pelo Google Tradutor e a tradução de referência elaborada por um humano. Nossa tradução (experimento 3) superou em 8% a tradução do Google segundo a métrica Meteor.





Figura 40 – Pontuações das opções de tradução conforme a lista NBest que criamos no Experimento 3, referente ao resumo 36.

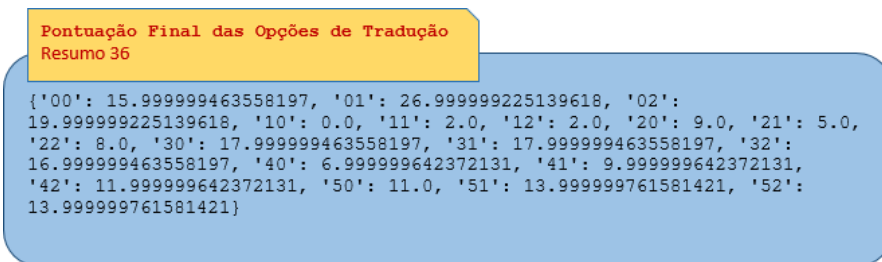



Figura 41 – Grafo referente a tradução do resumo 36 alcançado no Experimento 3 e exposto na Figura 39 (pág. 79).



pelo Google Tradutor. Em média, a vantagem dessas traduções corresponde a 2,2%. Com relação aos resultados restantes, 4 (9,3%) deles também se igualaram enquanto os demais 34 (79%) foram inferiores aos emitidos pelo Google Tradutor. Na Figura 42 (pág. 81) podemos comparar a melhor tradução gerada no Experimento 3 com a emitida pelo Google Tradutor.

Onde, na Figura 43 (pág. 81) temos a pontuação de cada opção de tradução e na Figura 44 (pág. 82) o respectivo grafo.

Figura 42 – Comparando a tradução do resumo 27 obtido no Experimento 3, com a gerada pelo Google Tradutor e a tradução de referencia elaborada por um humano. Nossa tradução (experimento 3) superou em 4% a tradução do Google segundo a métrica BLEU.

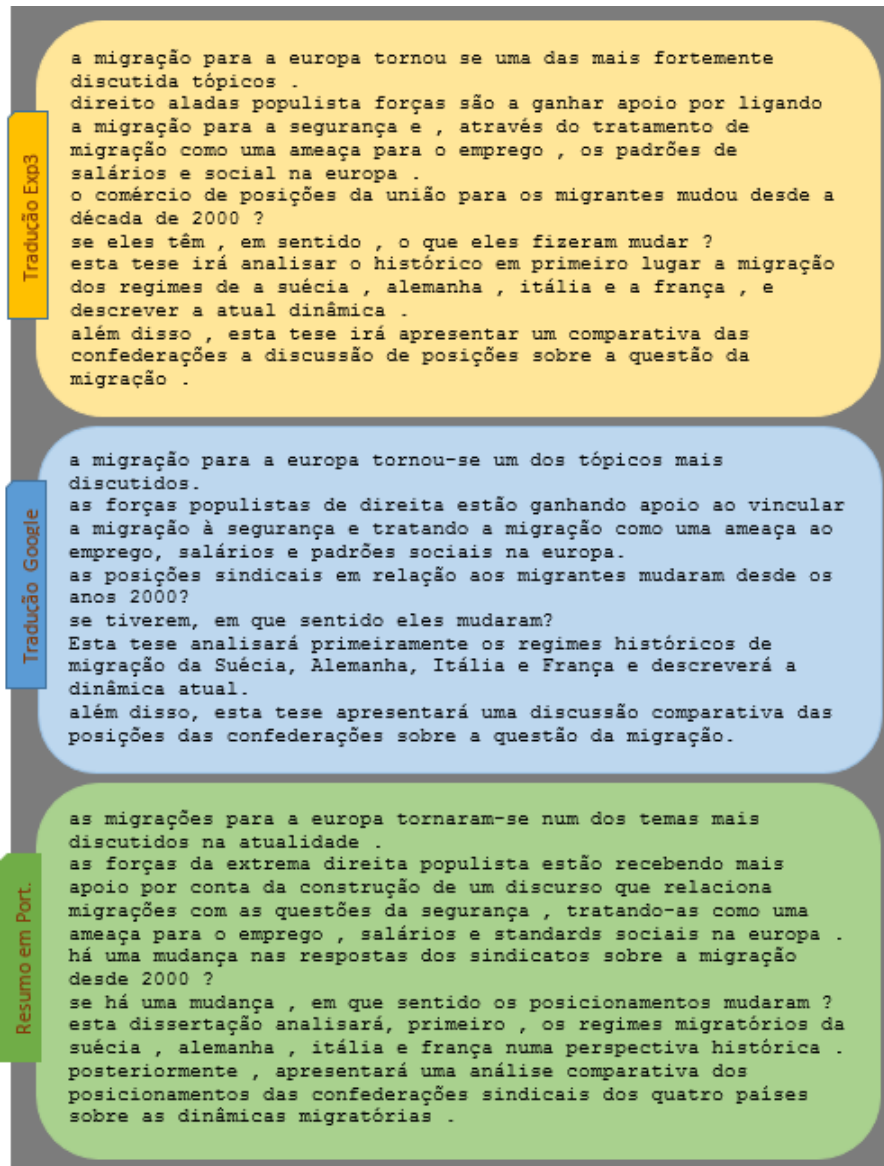


Figura 43 – Pontuações da Opções de tradução conforme a lista NBest que criamos no Experimento 3 referente ao resumo 27.

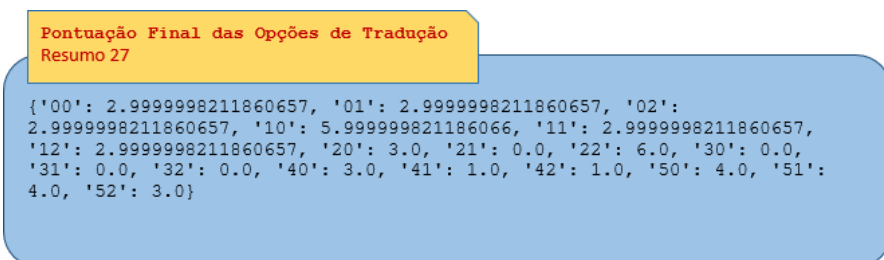



Figura 44 – Grafo referente a tradução do resumo 27 alcançado no Experimento 3 e exposto na Figura 42 (pág. 81).



### 5.3 Discussões dos Resultados

Os resultados alcançados em nossos 4 experimentos são distintos. Percebemos que no Experimento 1, nosso modelo de coerência pouco contribuiu para gerar traduções melhores quando comparadas as produzidas pelo Moses. Das que superaram, as métricas Meteor e BLEU constataram um ganho equivalente a média de 1%. Após verificarmos cada lista NBest sobre as quais aplicamos nossa técnica, constatamos que a diferença era mínima entre as 3 opções de tradução de cada frase. Concluimos que essa variação não ofereceu possibilidades para atuação do grafos de coerência e portanto, pouco afetou o resultado final. Considerando o ocorrido, proporcionamos para Experimento 2 um modelo de linguagem mais robusto (como descrito na Seção 5.2.2). Apuramos que nessa etapa, houve um aumento no numero de traduções, emitidas pela nossa técnica, que superaram as produzidas pelo Moses. Verificamos também cada lista NBest produzida e constatamos que elas apresentavam opções de tradução mais distintas quando comparadas com as produzidas no experimento anterior. Apesar disso, a contribuição destas diferenças entre as opções de tradução não foi suficiente para que nossa técnica proporcionasse resultados

que superassem os também 1% de média. Portanto, ao verificarmos ambas as etapas, elaboramos o terceiro experimento. Quando propomos considerar as traduções emitidas nos experimentos anteriores ( 5.2.1 e 5.2.2) e entre elas, selecionarmos as 3 melhores conforme as métricas de avaliação, conseguimos criar um cenário favorável ao nosso modelo de coerência. Neste novo cenário nosso sistema conseguiu traduções que nos chamaram a atenção pois, quase todas a traduções produzidas pelos grafos de coerência, superaram as melhores traduções das etapas anteriores. Confirmando assim que, neste cenário, nossa técnica é muito eficaz. Algumas dessas traduções apresentaram um qualificação tal que, quando comparadas a versão traduzida pelo Google Tradutor, elas ainda continuaram superiores, como registrado no Experimentos 4. Apesar de a maioria delas não ter superado essa máquina de tradução, a qualidade das suas traduções ficaram muito próximas, em sua maioria, do que o Google Tradutor produziu.

## 5.4 Resumo do Capítulo

Nesse capítulo apresentamos como nossas métricas de avaliação foram aplicadas. Em seguida, expomos os resultados alcançados em cada um dos quatro experimentos que realizamos e finalizamos com uma breve discussão a respeito do que foi produzido. Dando destaque as traduções que nosso modelo de coerência produziu e que concorreram em qualidade com as geradas por máquinas neurais. Mostrando-nos o seu potencial para a produção de traduções mais coesas.

## 5.5 Tabelas

Tabela 13 – Resultado Experimento 1 - SEM a TÉCNICA DE GRAFOS - conforme a métrica METEOR. Em vermelho, as traduções que se saíram melhores com as registradas na Tabela 14.

Resumos	Arquivos Moses.ini								
	1	2	3	4	5	6	7	8	9
01	0,36	0,39	0,36	0,30	0,26	0,17	0,34	0,16	0,28
02	0,45	0,44	0,42	0,38	0,38	0,23	0,43	0,21	0,41
03	0,41	0,38	0,38	0,31	0,29	-	0,36	0,20	0,38
04	0,41	0,46	0,43	0,40	0,32	0,28	0,40	0,22	0,43
05	0,33	0,34	0,29	0,33	0,25	0,16	0,32	0,13	0,30
06	0,36	0,39	0,40	0,37	0,28	-	0,39	0,20	0,31
07	0,37	0,40	0,40	0,29	0,41	0,21	0,30	0,22	0,32
08	0,41	0,43	0,38	0,35	0,35	0,24	0,40	0,22	0,40
09	0,33	0,34	0,33	0,19	0,27	0,15	0,29	0,13	0,26
10	0,50	0,49	0,44	0,47	0,38	0,30	0,40	0,33	0,44
11	0,41	0,40	0,37	0,32	0,29	0,25	0,59	0,20	0,31
12	0,36	0,37	0,34	0,38	0,33	0,25	0,45	0,19	0,39
13	0,36	0,38	0,34	0,34	0,25	0,18	0,36	0,14	0,34
14	-	-	0,36	-	0,36	0,24	0,52	0,20	0,35
15	0,48	0,55	0,49	0,51	0,46	0,25	0,56	0,21	0,57
16	0,39	0,43	0,41	0,36	0,39	0,25	0,42	0,24	0,40
17	0,45	0,45	0,50	0,44	0,43	0,20	0,54	0,19	0,29
18	0,30	0,33	0,30	0,28	0,26	0,18	0,32	0,17	0,28
19	0,29	0,32	0,25	0,35	0,30	0,23	0,36	0,20	0,36
20	0,34	0,33	0,32	0,33	0,30	0,29	0,38	0,22	0,36
21	0,46	0,45	0,45	0,40	0,39	-	0,44	0,22	0,33
22	0,47	0,53	0,47	0,45	0,42	-	0,46	0,23	0,45
23	0,29	0,26	0,26	0,28	0,26	0,17	0,29	0,16	0,28
24	0,41	0,42	0,41	0,32	0,31	-	0,41	0,24	0,37
25	0,40	0,39	0,40	0,41	0,34	0,32	0,43	0,22	0,40
26	0,54	0,56	0,49	0,47	0,47	-	0,56	0,19	0,52
27	0,34	0,34	0,26	0,30	0,27	0,25	0,35	0,20	0,29
28	0,44	0,46	0,39	0,43	0,36	0,18	0,54	0,18	0,46
29	0,43	0,41	0,44	0,38	0,43	0,22	0,42	0,16	0,47
30	0,48	0,51	0,47	0,44	0,37	0,23	0,45	0,20	0,43
31	0,46	0,51	0,48	0,47	0,39	0,22	0,50	0,23	0,37
32	0,31	0,32	0,32	0,30	0,29	-	0,31	0,22	0,35
33	0,40	0,41	0,40	0,41	0,34	0,20	0,36	0,21	0,41
34	0,46	0,47	0,41	0,44	0,33	-	0,51	0,27	0,41
35	0,28	0,23	0,30	0,26	0,21	0,19	0,24	0,15	0,20
36	0,60	0,56	0,50	0,56	0,50	-	0,62	0,34	0,59
37	0,51	0,56	0,54	0,53	0,46	-	0,58	0,37	0,54
38	0,49	0,44	0,44	0,40	0,43	-	0,54	0,32	0,49
39	0,45	0,42	0,42	0,36	0,35	0,24	0,51	0,25	0,42
40	0,47	0,45	0,43	0,41	0,37	0,23	0,48	0,18	0,41
41	0,43	0,39	0,37	0,39	0,36	0,23	0,38	0,22	0,37
42	0,42	0,43	0,39	0,37	0,35	0,23	0,41	0,24	0,39
43	0,37	0,36	0,37	0,34	0,33	0,22	0,40	0,19	0,34

Tabela 14 – Resultado Experimento 1 - COM a TÉCNICA DE GRAFOS - conforme a métrica METEOR. Em vermelho, as traduções que se saíram melhores com as registradas na Tabela 13.

Resumos	Arquivos Moses.ini								
	1	2	3	4	5	6	7	8	9
01	0,36	0,37	0,36	0,30	0,25	0,17	0,34	0,16	0,28
02	0,45	0,44	0,42	0,39	0,39	0,23	0,43	0,20	0,41
03	0,41	0,38	0,38	0,31	0,29	-	0,36	0,20	0,38
04	0,41	0,45	0,43	0,40	0,32	0,28	0,40	0,21	0,43
05	0,33	0,34	0,29	0,33	0,27	0,16	0,32	0,13	0,30
06	0,36	0,39	0,40	0,37	0,28	-	0,39	0,20	0,31
07	0,36	0,38	0,39	0,29	0,40	0,20	0,29	0,22	0,32
08	0,41	0,43	0,38	0,35	0,35	0,24	0,40	0,22	0,40
09	0,33	0,34	0,33	0,20	0,28	0,15	0,29	0,14	0,26
10	0,50	0,49	0,44	0,47	0,38	0,30	0,40	0,33	0,44
11	0,41	0,40	0,37	0,32	0,29	0,25	0,59	0,20	0,30
12	0,36	0,37	0,34	0,38	0,33	0,26	0,46	0,20	0,39
13	0,36	0,38	0,33	0,34	0,25	0,18	0,36	0,14	0,34
14	-	-	0,36	-	0,36	0,24	0,52	0,20	0,35
15	0,48	0,55	0,49	0,52	0,46	0,25	0,56	0,21	0,57
16	0,40	0,43	0,41	0,36	0,39	0,25	0,42	0,24	0,40
17	0,45	0,45	0,50	0,44	0,44	0,20	0,54	0,20	0,29
18	0,30	0,33	0,29	0,28	0,26	0,18	0,32	0,17	0,28
19	0,29	0,32	0,25	0,34	0,30	0,23	0,36	0,20	0,36
20	0,34	0,33	0,32	0,33	0,30	0,29	0,38	0,21	0,36
21	0,46	0,45	0,45	0,40	0,39	-	0,44	0,22	0,33
22	0,48	0,53	0,47	0,45	0,42	-	0,46	0,23	0,45
23	0,29	0,30	0,26	0,28	0,27	0,17	0,29	0,16	0,28
24	0,40	0,42	0,41	0,32	0,31	-	0,41	0,24	0,38
25	0,40	0,39	0,40	0,39	0,34	0,32	0,43	0,22	0,40
26	0,54	0,56	0,50	0,47	0,47	-	0,56	0,19	0,52
27	0,34	0,35	0,26	0,30	0,27	0,25	0,36	0,21	0,28
28	0,44	0,46	0,39	0,43	0,36	0,18	0,54	0,18	0,46
29	0,43	0,42	0,44	0,38	0,44	0,22	0,42	0,16	0,47
30	0,48	0,50	0,47	0,44	0,37	0,23	0,45	0,20	0,43
31	0,46	0,51	0,48	0,47	0,39	0,22	0,50	0,23	0,37
32	0,31	0,32	0,30	0,30	0,30	-	0,31	0,21	0,35
33	0,40	0,41	0,40	0,41	0,34	0,20	0,36	0,21	0,41
34	0,46	0,47	0,41	0,44	0,33	-	0,50	0,27	0,41
35	0,25	0,23	0,30	0,26	0,21	0,19	0,25	0,15	0,20
36	0,58	0,56	0,50	0,56	0,50	-	0,60	0,32	0,59
37	0,51	0,56	0,54	0,53	0,46	-	0,58	0,37	0,54
38	0,49	0,44	0,44	0,40	0,43	-	0,53	0,32	0,49
39	0,45	0,45	0,42	0,36	0,35	0,24	0,51	0,25	0,42
40	0,47	0,46	0,43	0,41	0,37	0,24	0,49	0,18	0,41
41	0,43	0,39	0,37	0,39	0,36	0,23	0,37	0,22	0,37
42	0,42	0,43	0,39	0,36	0,34	0,23	0,40	0,24	0,39
43	0,37	0,36	0,37	0,33	0,33	0,22	0,40	0,19	0,34



Tabela 15 – Resultado Experimento 1 - SEM a TÉCNICA DE GRAFOS - conforme a métrica BLEU. Em vermelho, as traduções que se saíram melhores com as registradas na Tabela 16.

Resumos	Arquivos Moses.ini								
	1	2	3	4	5	6	7	8	9
01	0,67	0,63	0,64	0,59	0,64	0,50	0,68	0,45	0,64
02	0,69	0,67	0,66	0,57	0,65	0,48	0,69	0,47	0,66
03	0,70	0,68	0,68	0,64	0,66	-	0,69	0,52	0,70
04	0,72	0,69	0,68	0,60	0,67	0,59	0,70	0,56	0,72
05	0,73	0,72	0,71	0,71	0,69	0,56	0,72	0,52	0,70
06	0,60	0,54	0,53	0,50	0,53	-	0,60	0,43	0,57
07	0,64	0,64	0,64	0,62	0,66	0,52	0,62	0,50	0,64
08	0,72	0,67	0,67	0,68	0,66	0,53	0,72	0,53	0,68
09	0,52	0,54	0,52	0,44	0,52	0,40	0,56	0,34	0,49
10	0,70	0,69	0,67	0,70	0,67	0,60	0,68	0,53	0,71
11	0,46	0,42	0,41	0,43	0,44	0,38	0,54	0,38	0,51
12	0,68	0,64	0,64	0,64	0,68	0,55	0,68	0,51	0,66
13	0,62	0,59	0,57	0,58	0,58	0,50	0,65	0,46	0,63
14	-	-	0,65	-	0,59	0,47	0,70	0,44	0,64
15	0,69	0,67	0,64	0,65	0,72	0,48	0,70	0,49	0,71
16	0,63	0,62	0,62	0,57	0,62	0,52	0,67	0,48	0,66
17	0,64	0,60	0,60	0,57	0,63	0,45	0,73	0,41	0,61
18	0,55	0,52	0,51	0,51	0,55	0,43	0,58	0,41	0,57
19	0,62	0,63	0,61	0,61	0,63	0,56	0,65	0,50	0,66
20	0,68	0,65	0,63	0,61	0,68	0,60	0,71	0,50	0,71
21	0,71	0,70	0,71	0,68	0,69	-	0,71	0,55	0,66
22	0,71	0,69	0,69	0,68	0,69	-	0,70	0,51	0,72
23	0,58	0,57	0,59	0,59	0,57	0,49	0,58	0,47	0,61
24	0,62	0,58	0,56	0,56	0,55	-	0,63	0,49	0,64
25	0,57	0,47	0,49	0,55	0,57	0,54	0,58	0,44	0,59
26	0,76	0,72	0,73	0,68	0,68	-	0,74	0,50	0,72
27	0,51	0,50	0,49	0,49	0,48	0,41	0,49	0,38	0,51
28	0,74	0,69	0,71	0,60	0,71	0,52	0,73	0,51	0,74
29	0,74	0,68	0,71	0,58	0,74	0,51	0,68	0,50	0,71
30	0,71	0,70	0,68	0,68	0,64	0,55	0,73	0,50	0,68
31	0,72	0,70	0,71	0,67	0,71	0,54	0,74	0,51	0,70
32	0,64	0,61	0,64	0,53	0,61	-	0,61	0,48	0,63
33	0,58	0,58	0,56	0,56	0,57	0,47	0,59	0,45	0,61
34	0,70	0,68	0,66	0,65	0,66	-	0,70	0,54	0,69
35	0,48	0,48	0,47	0,51	0,45	0,43	0,48	0,40	0,50
36	0,72	0,71	0,69	0,70	0,70	-	0,73	0,51	0,74
37	0,69	0,65	0,63	0,59	0,66	-	0,70	0,50	0,70
38	0,66	0,61	0,61	0,56	0,63	-	0,66	0,48	0,63
39	0,74	0,71	0,71	0,65	0,68	0,53	0,74	0,47	0,71
40	0,72	0,68	0,69	0,63	0,66	0,53	0,71	0,52	0,70
41	0,65	0,60	0,60	0,62	0,59	0,47	0,63	0,45	0,60
42	0,72	0,68	0,68	0,69	0,66	0,54	0,72	0,51	0,68
43	0,67	0,63	0,60	0,59	0,66	0,51	0,69	0,47	0,64

Tabela 16 – Resultado Experimento 1 - COM a TÉCNICA DE GRAFOS - conforme a métrica BLEU. Em vermelho, as traduções que se saíram melhores com as registradas na Tabela 15.

Resumos	Arquivos Moses.ini								
	1	2	3	4	5	6	7	8	9
01	0,67	0,62	0,64	0,59	0,65	0,50	0,68	0,45	0,64
02	0,69	0,67	0,66	0,58	0,66	0,47	0,69	0,46	0,66
03	0,70	0,68	0,68	0,64	0,66	-	0,68	0,52	0,70
04	0,72	0,68	0,68	0,60	0,67	0,59	0,70	0,55	0,71
05	0,73	0,73	0,71	0,71	0,69	0,56	0,72	0,52	0,70
06	0,59	0,55	0,54	0,50	0,53	-	0,60	0,43	0,57
07	0,63	0,64	0,64	0,62	0,66	0,53	0,61	0,50	0,64
08	0,72	0,67	0,67	0,68	0,66	0,53	0,72	0,53	0,68
09	0,52	0,54	0,52	0,43	0,52	0,40	0,56	0,34	0,49
10	0,70	0,69	0,67	0,69	0,67	0,61	0,68	0,53	0,71
11	0,46	0,42	0,40	0,43	0,44	0,38	0,54	0,38	0,51
12	0,68	0,65	0,64	0,63	0,68	0,55	0,68	0,51	0,66
13	0,62	0,59	0,57	0,58	0,58	0,50	0,65	0,46	0,63
14	-	-	0,64	-	0,59	0,46	0,71	0,44	0,64
15	0,69	0,67	0,64	0,65	0,72	0,48	0,70	0,49	0,71
16	0,64	0,62	0,61	0,57	0,62	0,52	0,66	0,48	0,66
17	0,64	0,60	0,60	0,57	0,63	0,45	0,73	0,41	0,61
18	0,55	0,51	0,52	0,51	0,55	0,43	0,58	0,42	0,57
19	0,62	0,63	0,61	0,61	0,63	0,55	0,65	0,50	0,66
20	0,68	0,64	0,63	0,60	0,68	0,60	0,71	0,50	0,71
21	0,71	0,70	0,71	0,68	0,69	-	0,71	0,54	0,66
22	0,72	0,69	0,69	0,68	0,69	-	0,70	0,51	0,72
23	0,58	0,56	0,59	0,59	0,57	0,49	0,58	0,47	0,61
24	0,62	0,58	0,56	0,56	0,55	-	0,63	0,49	0,64
25	0,57	0,47	0,49	0,54	0,57	0,54	0,57	0,43	0,59
26	0,75	0,72	0,73	0,68	0,68	-	0,74	0,50	0,72
27	0,51	0,50	0,51	0,49	0,48	0,41	0,49	0,38	0,51
28	0,74	0,69	0,71	0,60	0,71	0,51	0,73	0,51	0,74
29	0,74	0,68	0,70	0,58	0,73	0,51	0,68	0,50	0,71
30	0,71	0,69	0,68	0,68	0,64	0,55	0,73	0,50	0,68
31	0,72	0,70	0,71	0,68	0,71	0,54	0,74	0,51	0,70
32	0,63	0,61	0,63	0,53	0,61	-	0,61	0,49	0,63
33	0,58	0,58	0,56	0,56	0,57	0,48	0,59	0,45	0,61
34	0,70	0,68	0,66	0,65	0,66	-	0,70	0,54	0,70
35	0,49	0,48	0,47	0,51	0,45	0,43	0,48	0,40	0,50
36	0,72	0,71	0,69	0,70	0,70	-	0,72	0,52	0,74
37	0,69	0,65	0,63	0,59	0,66	-	0,70	0,50	0,70
38	0,66	0,61	0,61	0,56	0,63	-	0,65	0,48	0,63
39	0,74	0,71	0,71	0,65	0,68	0,53	0,73	0,47	0,71
40	0,72	0,69	0,69	0,63	0,66	0,53	0,71	0,52	0,70
41	0,64	0,60	0,60	0,62	0,59	0,47	0,64	0,46	0,60
42	0,72	0,68	0,68	0,69	0,66	0,53	0,72	0,52	0,68
43	0,67	0,63	0,60	0,59	0,66	0,51	0,69	0,47	0,64



Tabela 17 – Experimento 2 - Resultados obtidos pela métrica Meteor. Em vermelho, as traduções que se saíram melhores comparado a suas concorrentes.

Resumos	Arquivos Moses.ini					
	Sem a Técnica			Com a Técnica		
	G5	G7	G9	G5	G7	G9
01	0,32	0,39	0,30	0,30	0,35	0,30
02	0,39	0,43	0,40	0,41	0,41	0,41
03	0,30	0,36	0,32	0,31	0,36	0,33
04	0,32	0,39	0,37	0,32	0,39	0,37
05	0,31	0,30	0,30	0,31	0,32	0,30
06	0,32	0,38	0,34	0,33	0,40	0,33
07	0,39	0,34	0,36	0,39	0,35	0,36
08	0,40	0,35	0,37	0,40	0,35	0,37
09	0,32	0,25	0,34	0,32	0,25	0,33
10	0,50	0,45	0,50	0,50	0,46	0,50
11	0,30	0,41	0,30	0,30	0,41	0,30
12	0,35	0,43	0,40	0,35	0,43	0,40
13	0,33	0,36	0,37	0,33	0,36	0,37
14	0,36	0,42	-	0,38	0,42	-
15	0,54	0,55	0,53	0,54	0,55	0,49
16	0,38	0,45	0,44	0,37	0,45	0,44
17	0,37	0,50	0,44	0,37	0,50	0,43
18	0,26	0,31	0,26	0,26	0,31	0,26
19	0,31	0,37	0,30	0,31	0,37	0,30
20	0,35	0,34	0,38	0,36	0,34	0,37
21	0,35	0,46	0,35	0,35	0,46	0,35
22	0,40	0,43	0,44	0,40	0,43	0,44
23	0,25	0,27	0,27	0,27	0,28	0,27
24	0,31	0,41	0,34	0,31	0,41	0,34
25	0,36	0,37	0,36	0,36	0,37	0,36
26	0,47	0,42	0,51	0,49	0,42	0,51
27	0,29	0,32	0,27	0,29	0,32	0,27
28	0,37	0,48	0,46	0,38	0,49	0,49
29	0,44	0,47	0,50	0,44	0,47	0,51
30	0,40	0,40	0,42	0,40	0,40	0,42
31	0,44	0,48	0,41	0,44	0,48	0,41
32	0,28	0,31	0,30	0,28	0,30	0,30
33	0,44	0,38	0,39	0,44	0,38	0,39
34	0,37	0,43	0,42	0,37	0,43	0,42
35	0,21	0,23	0,23	0,21	0,23	0,23
36	0,55	0,63	0,62	0,55	0,61	0,62
37	0,46	0,53	0,50	0,48	0,54	0,50
38	0,41	0,44	0,44	0,41	0,44	0,44
39	0,40	0,48	0,44	0,40	0,48	0,44
40	0,40	0,47	0,38	0,40	0,47	0,38
41	0,40	0,35	0,37	0,40	0,35	0,36
42	0,41	0,39	0,38	0,41	0,38	0,37
43	0,37	0,38	0,37	0,37	0,40	0,37

Tabela 18 – Experimento 2 - Resultados obtidos pela métrica BLEU. Em vermelho, as traduções que se saíram melhores comparado a suas concorrentes.

Resumos	Arquivos Moses.ini					
	Sem a Técnica			Com a Técnica		
	G5	G7	G9	G5	G7	G9
01	0,68	0,67	0,69	0,69	0,68	0,68
02	0,70	0,70	0,71	0,70	0,70	0,71
03	0,72	0,72	0,72	0,72	0,72	0,72
04	0,70	0,70	0,73	0,70	0,70	0,73
05	0,70	0,70	0,71	0,70	0,71	0,72
06	0,61	0,59	0,60	0,61	0,59	0,60
07	0,69	0,63	0,66	0,69	0,63	0,66
08	0,71	0,72	0,72	0,71	0,72	0,72
09	0,53	0,54	0,55	0,53	0,54	0,55
10	0,70	0,70	0,73	0,70	0,70	0,73
11	0,49	0,52	0,51	0,49	0,52	0,51
12	0,67	0,69	0,69	0,67	0,69	0,69
13	0,63	0,66	0,66	0,63	0,66	0,66
14	0,68	0,67	-	0,68	0,67	-
15	0,74	0,72	0,75	0,74	0,72	0,74
16	0,66	0,64	0,67	0,65	0,64	0,67
17	0,66	0,66	0,68	0,66	0,66	0,68
18	0,57	0,54	0,60	0,57	0,54	0,60
19	0,66	0,68	0,66	0,66	0,67	0,66
20	0,72	0,71	0,74	0,73	0,71	0,73
21	0,66	0,69	0,65	0,67	0,70	0,65
22	0,67	0,69	0,71	0,67	0,69	0,71
23	0,63	0,60	0,63	0,63	0,60	0,63
24	0,60	0,70	0,65	0,60	0,70	0,66
25	0,61	0,62	0,59	0,61	0,62	0,58
26	0,76	0,73	0,77	0,75	0,73	0,77
27	0,54	0,53	0,56	0,54	0,53	0,56
28	0,76	0,74	0,78	0,75	0,74	0,78
29	0,75	0,71	0,75	0,75	0,71	0,75
30	0,71	0,69	0,72	0,71	0,69	0,72
31	0,73	0,70	0,73	0,73	0,70	0,74
32	0,64	0,63	0,66	0,64	0,63	0,66
33	0,63	0,60	0,63	0,63	0,61	0,63
34	0,69	0,68	0,71	0,69	0,68	0,71
35	0,52	0,55	0,55	0,52	0,55	0,55
36	0,72	0,75	0,75	0,72	0,75	0,75
37	0,70	0,68	0,72	0,71	0,68	0,72
38	0,70	0,70	0,71	0,70	0,70	0,71
39	0,74	0,75	0,75	0,74	0,75	0,75
40	0,70	0,72	0,74	0,70	0,72	0,74
41	0,71	0,72	0,72	0,71	0,72	0,72
42	0,71	0,72	0,72	0,71	0,72	0,73
43	0,69	0,69	0,68	0,69	0,68	0,68

Tabela 19 – Resultados alcançados nos experimentos 3 e 4. Considere Exp.3 como experimento 3.

Resumos	Métrica Meteor		Métrica BLEU	
	Exp.3	Google Tradutor	Exp.3	Google Tradutor
(<https://bit.ly/2Fg3Mn2>) 1	0,56	<b>0,60</b>	0,80	0,80
(<https://bit.ly/2DyHe0r>) 2	0,49	<b>0,54</b>	<b>0,80</b>	0,78
(<https://bit.ly/2QZUAGd>) 3	0,48	<b>0,77</b>	0,79	<b>0,83</b>
(<https://bit.ly/337VCFE>) 4	0,44	<b>0,52</b>	0,71	<b>0,82</b>
(<https://bit.ly/2DAGtnN>) 5	0,38	<b>0,53</b>	0,76	<b>0,81</b>
(<https://bit.ly/3lQqmDT>) 6	0,45	<b>0,50</b>	0,66	<b>0,71</b>
(<https://bit.ly/2F7jm4X>) 7	<b>0,42</b>	0,41	0,71	<b>0,74</b>
(<https://bit.ly/324vg8r>) 8	0,63	<b>0,65</b>	0,79	<b>0,81</b>
(<https://bit.ly/324aSnO>) 9	0,43	0,43	0,63	<b>0,66</b>
(<https://bit.ly/3h9RvOh>) 10	0,55	<b>0,70</b>	0,76	<b>0,86</b>
(<https://bit.ly/3h6rEqu>) 11	<b>0,66</b>	0,52	0,58	<b>0,79</b>
(<https://bit.ly/2FaH6ES>) 12	0,61	<b>0,64</b>	0,77	<b>0,82</b>
(<https://bit.ly/2F7YBWz>) 13	0,46	<b>0,62</b>	0,76	<b>0,83</b>
(<https://bit.ly/35dmpTU>) 14	0,41	<b>0,58</b>	0,72	<b>0,79</b>
(<https://bit.ly/3h5z914>) 15	<b>0,71</b>	0,67	<b>0,85</b>	0,81
(<https://bit.ly/33iADAn>) 16	0,54	<b>0,63</b>	0,75	<b>0,81</b>
(<https://bit.ly/2QWYxvg>) 17	<b>0,53</b>	0,48	0,71	<b>0,75</b>
(<https://bit.ly/3lS52hn>) 18	<b>0,38</b>	0,36	0,65	<b>0,68</b>
(<https://bit.ly/3lVtHI4>) 19	0,43	<b>0,47</b>	0,72	<b>0,76</b>
(<https://bit.ly/2ZdGQfx>) 20	0,42	<b>0,57</b>	0,74	<b>0,83</b>
(<https://bit.ly/2Fefu1v>) 21	<b>0,62</b>	0,60	0,75	<b>0,78</b>
(<https://bit.ly/2QWYW0K>) 22	<b>0,64</b>	0,62	0,79	<b>0,83</b>
(<https://bit.ly/2QXsVpv>) 23	0,36	<b>0,43</b>	0,70	<b>0,74</b>
(<https://bit.ly/2F8Pe8U>) 24	0,53	<b>0,57</b>	0,75	<b>0,76</b>
(<https://bit.ly/3bvPuLc>) 25	0,52	<b>0,68</b>	0,67	<b>0,79</b>
(<https://bit.ly/331nE5H>) 26	0,78	0,78	0,83	<b>0,86</b>
(<https://bit.ly/2F7kEwP>) 27	<b>0,41</b>	0,34	<b>0,66</b>	0,62
(<https://bit.ly/3jSgyHI>) 28	0,68	0,68	0,84	<b>0,89</b>
(<https://bit.ly/321KIYa>) 29	0,51	<b>0,53</b>	0,74	<b>0,81</b>
(<https://bit.ly/2GCIHVZ>) 30	0,53	<b>0,57</b>	<b>0,82</b>	0,81
(<https://bit.ly/2Zd1Q6i>) 31	0,58	<b>0,68</b>	0,78	<b>0,85</b>
(<https://bit.ly/357S3C9>) 32	0,36	<b>0,43</b>	0,72	<b>0,75</b>
(<https://bit.ly/2Zf7qoq>) 33	0,48	<b>0,55</b>	0,68	<b>0,73</b>
(<https://bit.ly/357XvVH>) 34	0,55	<b>0,64</b>	0,79	<b>0,83</b>
(<https://bit.ly/35adx14>) 35	0,40	<b>0,48</b>	0,63	<b>0,69</b>
(<https://bit.ly/3h4luas>) 36	<b>0,72</b>	0,64	0,82	<b>0,84</b>
(<https://bit.ly/3hdkLnH>) 37	0,63	<b>0,64</b>	<b>0,76</b>	0,75
(<https://bit.ly/3i4ZGNt>) 38	<b>0,60</b>	0,59	0,80	<b>0,81</b>
(<https://bit.ly/2Zen5o1>) 39	0,58	<b>0,63</b>	0,82	<b>0,84</b>
(<https://bit.ly/3lY4K8n>) 40	0,58	0,58	0,81	0,81
((<https://bit.ly/35awq44>) 41	0,54	<b>0,66</b>	0,83	<b>0,86</b>
(<https://bit.ly/2F3WjrH>) 42	0,58	<b>0,65</b>	0,78	<b>0,86</b>
(<https://bit.ly/3lY4Wo7>) 43	<b>0,48</b>	0,47	0,78	<b>0,80</b>

---

## Conclusão

O objetivo desse trabalho foi, por meio de nosso modelo de coerência, produzir traduções mais coesas, com uma relação semântica mais forte entre as sentenças. De forma que o produto final fosse uma tradução mais coerente e portanto, mais agradável para a leitura, aproximando-se da concepção humana.

Para isso, tomamos como base os modelos de coerência baseados em grafos desenvolvidos por Guinaudeau e Strub (GUINAUDEAU; STRUBE, 2013), Mesgan e Strub (MESGAR; STRUBE, 2015) e Born e co-autores (BORN; MESGAR; STRUBE, 2017). Assim desenvolvemos nosso próprio modelo de coerência baseado em grafos, onde apenas um conjunto de vértices passou a ser considerado. Constituído somente por palavras que gramaticalmente classificadas como substantivos, adjetivos e verbos, detectados apenas no idioma alvo mediante a teoria de Toury (1995).

A fim de construirmos nosso modelo, submetemos textos a uma máquina de tradução estatística por meio da qual, obtivemos documentos constituídos por 3 opções de tradução para cada sentença. Dispostos ordinariamente de forma que conseguimos os organizar computacionalmente. Sobre essas opções de tradução, aplicamos nosso modelo de coerência para a partir deles, selecionarmos as que melhor representavam suas respectivas sentenças, conforme a relação semântica que elas tinham entre si.

Para melhor compreensão do nosso modelo, foram realizados 4 experimentos distintos. Em cada um deles, avaliamos as traduções emitidas por nosso modelo de coerência, as produzidas pelo Moses (KOEHN et al., 2007) e as geradas pelo Google Tradutor, comparando-os uns com os outros. Para realizarmos isso, utilizamos as métrica de avaliação comumente empregadas na qualificação das traduções automáticas como, o Meteor (LAVIE; DENKOWSKI, 2009) e Bleu (PAPINENI et al., 2002).

Diante dos resultados obtidos pudemos perceber que, em cada experimento realizado, houve uma crescente evolução proporcionada por documentos com opções de traduções mais diferentes. Tal cenário contribuiu para que, em alguns casos, essa nova técnica sobressaísse em média 90% sobre o Moses (KOEHN et al., 2007) e 10% com relação ao

---

Google Tradutor. Comprovando a relevância de nosso modelo de coerência diante de múltiplas versões de um mesmo texto. Percebemos então, que a coerência pode ser tratada após um processo de tradução, ampliando nossa perspectiva quanto a evolução do estado da arte em relação a tradução automática.

---

# Referências

- ANACONDA. *Anaconda Individual Edition*. 2020. Disponível em: <<https://www.anaconda.com/distribution/>>. Acesso em: 23 mar. 2020.
- BAKHTIN, M. *Marxismo e filosofia da linguagem*. 1979.
- BARZILAY, R.; LAPATA, M. Modeling local coherence: An entity-based approach. *Computational Linguistics*, 2008. Disponível em: <[https://people.csail.mit.edu/regina/my\\_papers/coherence.pdf](https://people.csail.mit.edu/regina/my_papers/coherence.pdf)>.
- BENTIVOGLI, L. et al. Neural versus phrase-based machine translation quality: a case study. 2016. Disponível em: <<https://arxiv.org/pdf/1608.04631.pdf>>.
- BORN, L.; MESGAR, M.; STRUBE, M. Using a graph-based coherence model in document-level machine translation. *Proceedings of the Third Workshop on Discourse in Machine Translation*, p. 26–35, 2017. Disponível em: <<http://www.aclweb.org/anthology/W17-4803>>.
- CARVALHO, M. H. d. Estudo comparativo dos métodos de word embedding na análise de sentimentos. 2018. Disponível em: <[https://www.cin.ufpe.br/~tg/2018-2/TG\\_CC/tg\\_mhc.pdf](https://www.cin.ufpe.br/~tg/2018-2/TG_CC/tg_mhc.pdf)>.
- CASELI, H. d. M.; NUNES, I. A. Statistical machine translation: Little changes big impacts. In: *Proceedings of the 2009 Seventh Brazilian Symposium in Information and Human Language Technology*. USA: IEEE Computer Society, 2009. (STIL '09), p. 63–71. ISBN 9780769539454. Disponível em: <<https://doi.org/10.1109/STIL.2009.24>>.
- CASELI, H. d. M.; NUNES, I. A. Tradução automática estatística baseada em frases e fatorada: Experimentos com os idiomas português do Brasil e inglês usando o toolkit Moses. *Série de Relatórios do Núcleo Interinstitucional de Linguística Computacional*, 2009. Disponível em: <<http://www.nilc.icmc.usp.br/nilc/download/NILCTR-09-07.pdf>>.
- CHÉRAGUI, M. A. Theoretical overview of machine translation. *Knowledge-Based Systems*, 2012. Disponível em: <[https://www.researchgate.net/profile/Sahli\\_Nabil/publication/304041488\\_Security\\_Ontology\\_for\\_Semantic\\_SCADA/links/57647f7908aeb4b99800a26a.pdf#page=176](https://www.researchgate.net/profile/Sahli_Nabil/publication/304041488_Security_Ontology_for_Semantic_SCADA/links/57647f7908aeb4b99800a26a.pdf#page=176)>.
- DANE, F. Functional sentence perspective and the organization of the text. *Papers on Functional Sentence Perspective*, p. 106–128, 1974. Disponível em: <<https://pdfs.semanticscholar.org/c8df/e77906168e3025b7198c5000bb22114d6998.pdf>>.
- DOBRE, I. A comparison between BLEU and Meteor metrics used for assessing students within an informatics discipline course. *Procedia-Social and Behavioral Sciences*, Elsevier, v. 180, p. 305–312, 2015.

ELSNER, M.; AUSTERWEIL, J.; CHARNIAK, E. A unified local and global model for discourse coherence. *Proceedings of NAACL HLT*, p. 436–443, 2007. Disponível em: <<https://www.aclweb.org/anthology/N07-1055.pdf>>.

EVERS, A. *Processamento de Língua Natural e Níveis de Proficiência de Português: Um Estudo de Produções Textuais do Exame CELPE-BRAS*. Dissertação (Especialização) — Instituto de Letras, Universidade Federal do Rio Grande do Sul, 2013. Disponível em: <<http://www.ufrgs.br/acervocelpebras/arquivos/textos-publicados/evers-aline>>.

FREITAS, M. N. Substantivo ou adjetivo? um problema aspectual. 2007. Disponível em: <[http://www.filologia.org.br/xiv\\_cnlf/tomo\\_4/3233-3243.pdf](http://www.filologia.org.br/xiv_cnlf/tomo_4/3233-3243.pdf)>.

GRAESSER, A. C. et al. Coh-matrix: Analysis of text on cohesion and language. v. 36, n. 2, p. 193–202, 2004. Disponível em: <<https://link.springer.com/content/pdf/10.3758/BF03195564.pdf>>.

GUIMARÃES, I. C. T. O conceito de substantivo em uma perspectiva enunciativa. *Enunciação e materialidades linguísticas*, p. 19–37, 2015. Disponível em: <<http://www.letras.ufmg.br/site/e-livros/EnuncMaterialidadeLing2015.pdf#page=21>>.

GUINAUDEAU, C.; STRUBE, M. Graph-based local coherence modeling. In *Proceedings of the 51st Annual Meeting of the Association for Computational Linguistics*, p. 93–103, 2013. Disponível em: <<https://www.aclweb.org/anthology/P13-1010.pdf>>.

HARDMEIER, C. et al. Docent: A document-level decoder for phrase-based statistical machine translation. *Proceedings of the 51st Annual Meeting of the Association for Computational Linguistics*, p. 193–198, 2013. Disponível em: <<https://www.aclweb.org/anthology/P13-4033.pdf>>.

HOANG, H.; KOEHN, P. Design of the moses decoder for statistical machine translation. *Software Engineering, Testing, and Quality Assurance for Natural Language Processing*, p. 58–65, 2008. Disponível em: <[https://pdfs.semanticscholar.org/6ccd/d21a27d53ee46a07c282b93620bca6527c7c.pdf?\\_ga=2.246424391.2128185289.1581519263-1963603301.1581519263](https://pdfs.semanticscholar.org/6ccd/d21a27d53ee46a07c282b93620bca6527c7c.pdf?_ga=2.246424391.2128185289.1581519263-1963603301.1581519263)>.

HUTCHINS, W. Machine translation: A brief history. *Concise history of the language sciences: from the Sumerians to the cognitivists*, E.F.K.Koerner and R.E.Asher, p. 431–445, 1995.

HUTCHINS, W. J.; SOMERS, H. L. *An Introduction to Machine Translation*. [s.n.], 1992. Disponível em: <[psychotransling.ucoz.com/\\_ld/0/13\\_hutchins\\_2.doc](http://psychotransling.ucoz.com/_ld/0/13_hutchins_2.doc)>.

JABIN, S.; SAMAK, S.; SOKPHYRUM, K. Howto translate from english to khmer using moses. *International Journal of Engineering Inventions*, p. 71–81, 2013. Disponível em: <<http://www.ijejournal.com/papers/v3i2/M0327181.pdf>>.

KOEHN, P. Europarl: A Parallel Corpus for Statistical Machine Translation. 2005. Disponível em: <<http://mt-archive.info/MTS-2005-Koehn.pdf>>.

KOEHN, P. *Statistical Machine Translation System – User Manual and Code Guide*. [S.l.], 2013.

- KOEHN, P. et al. Moses: Open Source Toolkit for Statistical Machine Translation. *ACL '07 Proceedings of the 45th Annual Meeting of the ACL on Interactive Poster and Demonstration Sessions*, p. 177–180, 2007. Disponível em: <<https://dl.acm.org/citation.cfm?id=1557821>>.
- KOEHN, P.; KNOWLES, R. Six challenges for neural machine translation. *Proceedings of the First Workshop on Neural Machine Translation*, p. 28–39, 2017. Disponível em: <<https://arxiv.org/pdf/1706.03872.pdf>>.
- KOEHN, P.; OCH, F. J.; MARCU, D. Statistical Phrase-Based Translation. *HLT-NAACL – Mein Papers*, p. 48 – 54, 2003. Disponível em: <<http://www.aclweb.org/anthology/N03-1017>>.
- LAPA, M. R. Estilística da língua portuguesa. 1977.
- LAPATA, M.; BARZILAY, R. Automatic evaluation of text coherence: Models and representations. *IJCAI-05, Proceedings of the Nineteenth International Joint Conference on Artificial Intelligence*, p. 1085–1090, 2005. Disponível em: <<https://dl.acm.org/doi/10.5555/1642293.1642467>>.
- LAVIE, A.; DENKOWSKI, M. The Meteor Metric for Automatic Evaluation of Machine Translation. 2009. Disponível em: <<https://link.springer.com/article10.1007%2Fs10590-009-9059-4?LI=true>>.
- LENOVO. *PC 2 em 1*. 2020. Disponível em: <<https://www.lenovo.com/br/pt/laptops/ideapad/ideapad-s-series/Lenovo-IdeaPad-S145-15IWL/p/88IPS101200>>. Acesso em: 10 mar. 2020.
- LIN, Z.; NG, H. T.; KAN, M.-Y. Automatically evaluating text coherence using discourse relations. *Proceedings of the 49th Annual Meeting of the Association for Computational Linguistics*, p. 997–1006, 2011. Disponível em: <<https://www.aclweb.org/anthology/P11-1100.pdf>>.
- LOPEZ, A. Statistical Machine Translation. *ACM Computing Surveys*, v. 40, n. 3, 2008. Disponível em: <<https://dl.acm.org/citation.cfm?id=1380586>>.
- MARTINS, D. B. d. J.; CASELI, H. d. M. Anotação manual de erros de tradução automática em textos traduzidos de inglês para português do brasil. *Série de Relatórios do Núcleo Interinstitucional de Linguística Computacional*, 2013. Disponível em: <<http://www.nilc.icmc.usp.br/nilc/download/NILC-TR-13-02>>.
- MARTINS, R. T.; NUNES, M. d. G. V. Noções gerais de tradução automática. *NOTAS DIDÁTICAS DO ICMC-USP*, v. 68, 2005. Disponível em: <[http://www.nilc.icmc.usp.br/nilc/download/NotasDidaticasICMC\\_68.pdf](http://www.nilc.icmc.usp.br/nilc/download/NotasDidaticasICMC_68.pdf)>.
- MENACER, M. A. et al. Is statistical machine translation approach dead? 2017. Disponível em: <<https://hal.inria.fr/hal-01660016>>.
- MESGAR, M.; STRUBE, M. Graph based coherence modeling for assessing readability. *In Proceedings of the Fourth Joint Conference on Lexical and Computational Semantics*, p. 309–318, 2015. Disponível em: <<https://www.aclweb.org/anthology/S15-1036.pdf>>.



MESGAR, M.; STRUBE, M. Lexical coherence graph modeling using word embeddings. *Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, p. 1414–1423, 2016. Disponível em: <<https://www.aclweb.org/anthology/N16-1167.pdf>>.

NETWORKX. *Overview of NetworkX*. 2020. Disponível em: <<https://networkx.github.io/documentation/stable/>>. Acesso em: 10 mar. 2020.

NIJSSSEN, S.; KOK, J. N. The gaston tool for frequent subgraph mining. *Electronic Notes in Theoretical Computer Science* 127, p. 77–87, 2005. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1571066105001064>>.

NILC. *Repositório de word embedding no NILC*. 2020. Disponível em: <<http://nilc.icmc.usp.br/embeddings>>. Acesso em: 09 mar. 2020.

NUNES, I. A.; CASELI, H. d. M. Primeiros experimentos na investigação e avaliação da tradução automática estatística inglês - português. *Anais do Workshop de Iniciação Científica em Tecnologia da Informação e da Linguagem Humana*, 2009. Disponível em: <[http://www.nilc.icmc.usp.br/til/stil2009\\_English/Proceedings/tilic/NunesCaseli.pdf](http://www.nilc.icmc.usp.br/til/stil2009_English/Proceedings/tilic/NunesCaseli.pdf)>.

PAPINENI, K. et al. BLEU : a Method for Automatic Evaluation of Machine Translation. *Proceedings of the 40th Annual Meeting of the Association for Computational Linguistics (ACL)*, 2002.

PARVEEN, D.; MESGAR, M.; STRUBE, M. Generating Coherent Summaries of Scientific Articles Using Coherence Patterns. *Conference on Empirical Methods in Natural Language Processing*, n. 1 - 5, p. 772 – 783, 2016. Disponível em: <<http://www.aclweb.org/anthology/D16-1074>>.

PENNINGTON, J.; SOCHER, R.; MANNING, C. D. Glove: Global vectors for word representation. 2014. Disponível em: <<https://nlp.stanford.edu/pubs/glove.pdf>>.

PEREIRA, G. M. R.; CÂMARA, M. A. d. Algumas Aplicações da Teoria dos Grafos . *FAMAT*, n. 11, p. 67 – 80, 2008. Disponível em: <[http://www.pucrs.br/ciencias/viali/graduacao/po\\_2/literatura/grafos/artigos/Famat\\_artigo\\_04.pdf](http://www.pucrs.br/ciencias/viali/graduacao/po_2/literatura/grafos/artigos/Famat_artigo_04.pdf)>.

PYTHON.ORG. *Estrutura de Dados*. 2020. Disponível em: <<https://docs.python.org/pt-br/3/tutorial/datastructures.html>>. Acesso em: 10 mar. 2020.

RIBEIRO, G. C. B. Avaliação de tradução automática no mercado de localização de software: um estudo de caso. 2006. Disponível em: <[https://www.maxwell.vrac.puc-rio.br/9105/9105\\_1.PDF](https://www.maxwell.vrac.puc-rio.br/9105/9105_1.PDF)>.

SALTON, G. The smart retrieval system – experiments in automatic document processing. 1971.

SILVA, D. M. d. Python: História e ascendência. *Revista Programar*, António Pedro Cunha Santos, Rita Peres, v. 59, p. 96–99, 2018. Disponível em: <<https://www.revista-programar.info/edicoes/edicao-59/>>.

SILVA, I. L. L.; TORRES, F. F.; BRASIL, C. G. F. A progressão temática em língua portuguesa: uma análise de notícias sobre a operação lava jato no jornal folha de são paulo. *Entrepalavras*, p. 169–188, 2018. Disponível em: <<http://www.entrepalavras.ufc.br/revista/index.php/Revista/article/view/1205>>.

SOARES, F.; MOREIRA, V. P.; BECKER, K. *A Large Parallel Corpus of Full-Text Scientific Articles*. 2019.

SPACY. *spaCy - Tudo o que você precisa saber*. 2020. Disponível em: <<https://spacy.io/usage/spacy-101#whats-spacy>>. Acesso em: 14 fev. 2020.

TILLMANN, C.; NEY, H. Word reordering and a dynamic programming beam search algorithm for statistical machine translation. *Association for Computational Linguistics*, 2003. Disponível em: <<https://www.mitpressjournals.org/doi/pdf/10.1162/089120103321337458>>.

TOURY, G. *Descriptive Translation Studies – and beyond*. Philadelphia, PA.: John Benjamins Publishing, 1995. ISBN 9781556194955.

TRAVAGLIA, L. C. Contribuições do verbo à coesão e à coerências textuais. *Cad.Est.Ling., Campinas*, v. 27, p. 71–84, 1994. Disponível em: <<https://periodicos.sbu.unicamp.br/ojs/index.php/cel/article/view/8637030/4752>>.

UBUNTU LINUX. *Resumo do Produto*. 2020. Disponível em: <<https://ubuntu.com/download/desktop>>. Acesso em: 23 mar. 2020.

USP - PANDA CURSO DE COMPUTAÇÃO. *Como pensar como um Cientista da Computação*. 2020. Disponível em: <<https://panda.ime.usp.br/pensepy/static/pensepy/11-Dicionarios/dicionarios.html>>. Acesso em: 10 mar. 2020.

WESTERN DIGITAL. *Resumo do Produto*. 2020. Disponível em: <[https://documents.westerndigital.com/content/dam/doc-library/pt\\_br/assets/public/western-digital/product/internal-drives/wd-blue-sn500-nvme-ssd/product-brief-wd-blue-sn500-nvme-ssd.pdf](https://documents.westerndigital.com/content/dam/doc-library/pt_br/assets/public/western-digital/product/internal-drives/wd-blue-sn500-nvme-ssd/product-brief-wd-blue-sn500-nvme-ssd.pdf)>. Acesso em: 23 mar. 2020.

WU, Y. et al. *Google's Neural Machine Translation System: Bridging the Gap between Human and Machine Translation*. 2016.

Xiong, D.; Zhang, M.; Wang, X. Topic-Based Coherence Modeling for Statistical Machine Translation. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, v. 23, n. 3, p. 483–493, 2015.