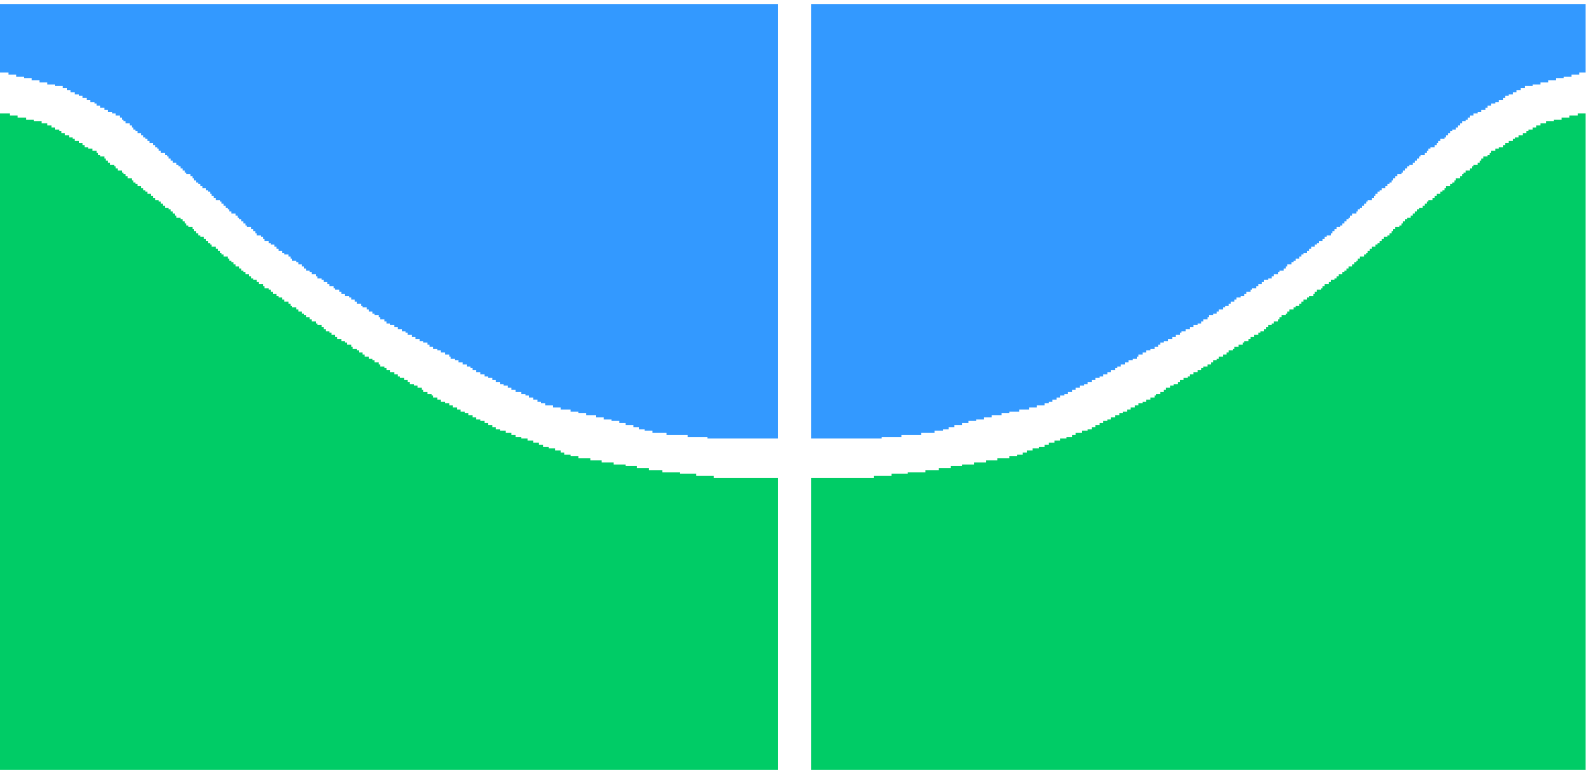

Universidade de Brasília - UnB

Faculdade UnB Gama - FGA

Engenharia de software

Aplicação de processamento de linguagem natural: Uma ferramenta de apoio à correção de questões dissertativas

Autor: Cristóvão de Lima Frinhani

Orientador: Professor Doutor Sérgio Antônio Andrade de Freitas

Brasília, DF

2015

Cristóvão de Lima Frinhani

Aplicação de processamento de linguagem natural: Uma ferramenta de apoio à correção de questões dissertativas

Monografia submetida ao curso de graduação em (Engenharia de software) da Universidade de Brasília, como requisito parcial para obtenção do Título de Bacharel em (Engenharia de software).

Universidade de Brasília - UnB

Faculdade UnB Gama - FGA

Orientador: Professor Doutor Sérgio Antônio Andrade de Freitas

Coorientador: Mestre Maurício Vidotti Fernandes

Brasília, DF

2015

Cristóvão de Lima Frinhani

Aplicação de processamento de linguagem natural: Uma ferramenta de apoio à correção de questões dissertativas/ Cristóvão de Lima Frinhani. – Brasília, DF, 2015-

69 p. : il. (algumas color.) ; 30 cm.

Orientador: Professor Doutor Sérgio Antônio Andrade de Freitas

Trabalho de Conclusão de Curso – Universidade de Brasília - UnB
Faculdade UnB Gama - FGA , 2015.

1. Palavra-chave01. 2. Palavra-chave02. I. Professor Doutor Sérgio Antônio Andrade de Freitas. II. Universidade de Brasília. III. Faculdade UnB Gama. IV. Aplicação de processamento de linguagem natural: Uma ferramenta de apoio à correção de questões dissertativas

CDU 02:141:005.6

Cristóvão de Lima Frinhani

Aplicação de processamento de linguagem natural: Uma ferramenta de apoio à correção de questões dissertativas

Monografia submetida ao curso de graduação em (Engenharia de software) da Universidade de Brasília, como requisito parcial para obtenção do Título de Bacharel em (Engenharia de software).

Trabalho aprovado. Brasília, DF, 27 de novembro de 2015:

Professor Doutor Sérgio Antônio Andrade de Freitas
Orientador

Professora Doutora Carla Silva Rocha Aguiar
Convidado 1

Professor Doutor Edgard Costa Oliveira
Convidado 2

Brasília, DF
2015

Este trabalho é dedicado às crianças adultas que,
quando pequenas, sonharam em se tornar cientistas.

Agradecimentos

Agradeço primeiramente a Deus, por está vivo até hoje, agradeço aos meus pais, minha mãe Sebastiana, ao meu pai Leandro, por sempre me apoiarem, e desde a simplicidade nunca deixaram me faltar nada, me ensinado sempre a ser uma pessoa digna, agradeço ao meu irmão Fábio, que agora também segue seu caminho na graduação, por me apoiar e está comigo em algumas das noites em claro de estudos, agradeço a minha namorada Anacarina, por está comigo em meus momentos de lazer e descanso necessários para fazer esse TCC, agradeço aos meus amigos presentes da FGA que estão comigo por todo esse caminho, agradeço ao meu professor orientador Sérgio por me guiar nesse tema de TCC, agradeço ao meu coorientador Maurício por todas as longas conversas de fim de tarde, agradeço a todos os professores da FGA, por sempre fazerem o possível por uma faculdade melhor.

Sapere aude

Resumo

O ensino a distância é uma modalidade de ensino que tem crescido. Porem tem encontrado barreiras em sua escalabilidade. A correção de questões dissertativas normalmente leva um maior tempo que questões de certo ou errado e múltiplas escolhas, buscado auxiliar o tutor em seu trabalho de correção de questões dissertativas, se pensou em um sistema de apoia de pré-avaliação, onde o tutor poderá inseri perguntas e respostas e os alunos respondessem, para isso foi estudado o processamento de linguagem natural, onde a aplicação de similaridade semântica pode quantificar uma resposta com um gabarito, para minimizar o erro da quantificação, foi estudado o aprendizado de máquina, para se adquirir conhecimento com a interação do tutor.

Palavras-chaves: Similaridade semântica. Processamento de linguagem natural. Aprendizado de máquina. Algoritmo genético. Questões dissertativas. Apoio a correção.

Abstract

Distance learning is a teaching modality that has grown.However they have found barriers in its scalability. The correction essay questions usually takes a longer time to questions of right or wrong and multiple choices, sought to assist the tutor in his work of correction of essay questions, it was thought in a supportive pre-assessment system, where the tutor can enter questions and answers and the students respond to it, has been studied the natural language processing, where the application of semantic similarity can quantify an answer with a template to minimize the error of measurement, machine learning was studied to gain knowledge through interaction with the tutor.

Key-words: Semantic Similarity. Natural language processing. Machine learning. Genetic algorithm. Essay questions. Support for correction.

Lista de ilustrações

Figura 1 – Relação de número de cursos à distância (virtuais) por ano no Brasil. Fonte:(ABRAEAD, 2008) 25
Figura 2 – Exemplo da representação do LSA. Fonte:(LANDAUER; FOLTZ; LAHAM, 1998) 32
Figura 3 – Exemplo da representação da decomposição SVD. Fonte:(LANDAUER; FOLTZ; LAHAM, 1998) 33
Figura 4 – Exemplo da matriz Xhihat. Fonte:(LANDAUER; FOLTZ; LAHAM, 1998) 33
Figura 5 – Hierarquia do aprendizado 36
Figura 6 – Completude e consistência de uma hipótese. Fonte:(REZENDE, 2003) . 40
Figura 7 – Fluxograma do algoritmo genético *standard*. Fonte:(CARRIJO, 2004) . 43
Figura 8 – Esquema da Roleta. Fonte:(SILVA, 2005) 45
Figura 9 – Esquema do Torneio. Fonte:(SILVA, 2005) 45
Figura 10 – Esquemas de uma recombinação simples. Fonte:(CARRIJO, 2004) . . . 47
Figura 11 – Ciclo de interação do MVC. Fonte:(KRASNER; POPE, 1988) 52
Figura 12 – Representa os passos no processo do Sistema de apoio de correção de respostas dissertativas 54
Figura 13 – Representa os passos no processo de análise de texto. 57

Lista de tabelas

Tabela 1 – Características gerais de sistemas de Aprendizado de Máquina 36
Tabela 2 – Conjunto de exemplos no formato atributo-valor 38
Tabela 3 – Matriz de confusão de um classificador 40
Tabela 4 – Exemplo de seleção pelo método da roleta(SILVA, 2005) 44
Tabela 5 – *Backlog* do Produto 60
Tabela 6 – Eu como usuário quero logar no sistema para que meu perfil seja identificado. 60
Tabela 7 – Eu como Tutor quero cadastrar exames para poder cadastrar questões. 60
Tabela 8 – Eu como Tutor quero cadastrar questões e gabaritos para aplicar aos meus alunos. 61
Tabela 9 – Eu como Tutor quero inserir respostas há minha questão para treinar o sistema. 61
Tabela 10 – Eu como Aluno quero responder a questões para que eu possa ser avaliado. 61
Tabela 11 – Eu como Tutor quero poder mudar a nota dada pelo sistema para corrigir a divergência de nota dada. 61
Tabela 12 – Eu como Tutor quero poder disponibilizar as notas no sistema para meus alunos. 61
Tabela 13 – Eu como Aluno quero ver minha correção para que eu possa entender como minha resposta foi avaliada. 61
Tabela 14 – Eu como Aluno quero poder entrar com recurso para que minha nota seja reavaliada. 61
Tabela 15 – Eu como Tutor quero mudar uma nota mesmo depois de fechada para poder atender um recurso pedido por um aluno. 62
Tabela 16 – Eu como Aluno quero poder ver os recursos que eu cadastrei para ver o andamento dele. 62
Tabela 17 – Cronograma de trabalho para o TCC1 63
Tabela 18 – Cronograma de trabalho para o TCC2 63
Tabela 19 – Disposição das histórias nas *sprints* 63

Lista de abreviaturas e siglas

PLN	Processamento de linguagem natural
LSA	*Latent Semantic Analysis*
AVA	Ambiente virtual de aprendizado
MVC	*Model View Controller*
EAD	Educação a distância
NLTK	*Natural Language Toolkit*
ISA	*Is a kind of*
URL	*Uniform Resource Locator*
IP	*Internet Protocol*

Lista de símbolos

$\sum$	Letra grega sigma
$=$	Igualdade
δ	Letra grega minúscula delta
$\|$	Norma
$\approx$	Aproximadamente igual
$\neq$	Diferente

Sumário

1 INTRODUÇÃO . . . 25
1.1 Objetivos . . . 25
1.1.1 Objetivos Geral . . . 25
1.1.2 Objetivos específicos . . . 26
1.1.3 Questão de pesquisa . . . 26
1.2 Motivação . . . 26
1.3 Metodologia . . . 26
1.3.1 Classificação da pesquisa . . . 27
1.3.2 Referencial teórico . . . 27
1.3.3 Proposta . . . 27
1.3.4 Engenharia de software . . . 27
1.4 Estrutura da Monografia . . . 27

2 REFERENCIAL TEÓRICO . . . 29
2.1 Processamento de Linguagem Natural . . . 29
2.2 Algoritmos de Similaridade . . . 29
2.2.1 Pré-processamento . . . 30
2.2.1.1 *Tokenization* . . . 30
2.2.1.2 Remoção de *stopwords* . . . 31
2.2.1.3 *Lemmatization* . . . 31
2.2.2 *Latent Semantic Analysis*(LSA) . . . 31
2.2.3 *STASIS* . . . 32
2.3 *Machine Learning* . . . 34
2.3.1 Aprendizado Supervisionado Conceitos e Definições . . . 36
2.4 Algoritmo genético . . . 41
2.4.1 Terminologia . . . 41
2.4.2 O algoritmo . . . 41
2.4.2.1 Iniciação da população . . . 42
2.4.2.2 Seleção dos Pais . . . 42
2.4.2.3 Função de aptidão . . . 43
2.4.2.4 Métodos de seleção . . . 44
2.4.2.4.1 Roleta . . . 44
2.4.2.4.2 Torneio . . . 44
2.4.2.4.3 Amostragem Estocástica . . . 44
2.4.2.5 Operadores Genéticos . . . 45

2.4.2.5.1 Cruzamento, Recombinação ou *Crossover* . . . 46
2.4.2.5.2 Mutação . . . 46
2.4.2.6 Subistituição . . . 46
2.4.2.7 Parâmetros Genéticos . . . 47
2.4.2.7.1 Tamanho da População . . . 48
2.4.2.7.2 Taxa de cruzamento . . . 48
2.4.2.7.3 Taxa de Mutação . . . 48
2.4.2.7.4 Taxa de Substituição . . . 48
2.4.2.7.5 Critérios de parada . . . 48
2.4.2.7.6 Problema de Convergência . . . 48
2.5 Engenharia de Software . . . 49
2.5.1 Metodologia Scrum . . . 49
2.5.1.1 O time Scrum . . . 49
2.5.1.2 Eventos do Scrum . . . 50
2.5.1.2.1 *Sprint* . . . 50
2.5.1.2.2 Reunião de Planejamento da *Sprint* . . . 50
2.5.1.2.3 Revisão da *Sprint* . . . 51
2.5.1.3 Artefatos do Scrum . . . 51
2.5.1.3.1 *Backlog* do Produto . . . 51
2.5.1.3.2 *Backlog* da *Sprint* . . . 51
2.5.2 Arquitetura *Model View Controller*(MVC) . . . 51
2.5.3 Paradigma Orientado a Objetos . . . 51

3 A PROPOSTA . . . 53
3.1 Introdução . . . 53
3.2 O processo . . . 54
3.3 Análise do texto . . . 56
3.4 Algoritmo genético . . . 58

4 DESENVOLVIMENTO DA PROPOSTA . . . 59
4.1 Descrição do projeto . . . 59
4.2 Proposta . . . 59
4.3 O sistema . . . 59
4.4 Definição das tecnologias . . . 62
4.5 Cronograma de desenvolvimento . . . 62

5 CONSIDERAÇÕES FINAIS . . . 65

Referências . . . 67

1 INTRODUÇÃO

Com o avanço das tecnologias, os métodos de ensino e aprendizagem se modificaram, cada vez mais é necessário se atualizar para se manter dentro do contexto competitivo e social da sociedade, não sendo isso mais uma exclusividade dos jovens.(PEREIRA; SCHMITT; DIAS, 2007).

Com isso os Ambientes Virtuais de Aprendizagem (AVAs), estão sendo cada vez mais utilizados pela acadêmia e corporações como uma opção tecnológica para suprir a demanda educacional.(PEREIRA; SCHMITT; DIAS, 2007).

O moodle, um AVA, possui o recurso de questionário que permite o professor aplicar questionários nesses ambientes, em sua maioria a correção desses é automatizada, como os tipos verdadeiro ou falso e de múltipla escolha, questões dissertativas não são corrigidas automaticamente(FILHO, 2009).

	Ano Declarado																
	1992	1993	1994	1995	1996	1997	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008*
Nº de Cursos	1	1	1	3	6	9	6	10	14	9	10	22	45	78	194	320	8

Figura 1 – Relação de número de cursos à distância (virtuais) por ano no Brasil. Fonte:(ABRAEAD, 2008)

Esse crescimento pode ser visto na figura 1 do Anuário Brasileiro Estatístico de Educação Aberta e a Distância (ABRAEAD, 2008), no ano de 2007 com total de 320 cursos oferecidos à distância.

1.1 Objetivos

São apresentados nesta seção os objetivos gerais, objetivos específicos e a questão de pesquisa.

1.1.1 Objetivos Geral

Desenvolver um sistema de apoio a correção de questões dissertativas, utilizando de técnicas de processamento de linguagem natural, para a similaridade dos textos e *Machine Learning* para criar um fator de aprendizado que melhore sua eficiência com as interações

1.1.2 Objetivos específicos

Os objetivos deste trabalho são:

- Criar uma metodologia para a definição dos gabaritos, os gabaritos serão usados para o calculo da similaridade.
- Construir um sistema capaz de fazer pre-avaliações de respostas de questões dissertativas dando uma nota.
- Construir um sistema capaz de usar *Machine Learning* para minimizar o e erro da valoração das questões dissertativas.
- Construir uma integração com o moodle.
- Avaliar a eficiência do sistema implantado.

1.1.3 Questão de pesquisa

A questão que esse trabalho tenta responder é: É possível criar um sistema de apoio que pre-avalie questões dissertativas, que guie o tutor na correção, e ao mesmo tempo aprenda com essa interação, para sua melhoria ?

1.2 Motivação

Diversos fatores despertam a motivação deste trabalho, sendo alguns deles de curiosidade e estudo, e outros para auxiliar tutores e estudantes em seu caminho de aprendizado, posso descrever que são os principais motivos:

- Entendimento do processamento de linguagens naturais.
- Entendimento do processo de aprendizado de maquina.
- Auxiliar tutores na correção de respostas dissertativas.
- Ajudar os alunos a receberem suas notas em menor tempo.

1.3 Metodologia

Esss seção apresenta a metodologia que será usada no desenvolvimento deste trabalho:

1.3.1 Classificação da pesquisa

Segundo (GIL, 2008) com base nos objetivos, uma pesquisa é classificada como exploratório, descritiva ou explicativa.

A pesquisa exploratória tem como objetivo a familiaridade com o problema, tornando ele mais explicativo ou construindo hipóteses, sendo flexível em seu planejamento assume na maioria dos casos a forma de pesquisa bibliográfica ou de estudo de caso(GIL, 2008).

Com base nos objetivos do trabalho, ele se classifica como exploratório.

1.3.2 Referencial teórico

Para a pesquisa de referencial teórico de similaridade semântica e algoritmos genéticos, serão pesquisados em livros e artigos, tanto por meio físico e digital. Os conceitos estudados serão sumarizados e descritos no capítulo 3 de referencial teórico.

1.3.3 Proposta

Uma vez estudado o referencial teórico e tendo os objetivos definidos, foi proposto um escopo do sistema aonde foi definido o passo a passo do processo que o sistema irá seguir para alcançar os objetivos.

1.3.4 Engenharia de software

Para a implementação serão consideradas as praticas da *framework* Scrum, criando um *backlog* de produto e dividindo seu desenvolvimento em *sprints*, para o desenvolvimento do sistema serão utilizados o paradigma de programação orientado a objetos e um padrão arquitetural MVC.

1.4 Estrutura da Monografia

Este trabalho possui 5 partes: INTRODUÇÃO, referencial teórico, a Proposta, o Desenvolvimento da Proposta e considerações finais, no capítulo 1 é apresentada a introdução, no capítulo 2 é feito um estudo sobre o referencial teórico, no capítulo 3 é apresentada a proposta de sistema e no capítulo 4 é feito o levantamento necessário de engenharia de software para o desenvolvimento do sistema.

2 Referencial Teórico

Este capítulo tem como objetivo apresentar o referencial teórico que embasa a pesquisa deste trabalho, incluindo conceitos abordados, tais como a processamento de linguagem natural, algoritmos de similaridade e *Machine Learning*.

2.1 Processamento de Linguagem Natural

Com uma quantidade de páginas, a web se constitui hoje quase todas de linguagem natural, com isso um agente que deseja adquirir conhecimento tem que entender a ambiguidade e confusão da linguagem humana(RUSSELL; NORVIG, 2013).

As linguagens naturais não podem ser definidas como um conjunto de sentenças definidas. Com isso se torna melhor definir um modelo de linguagem natural usando probabilidade sobre sentenças em vez de um conjunto definido(RUSSELL; NORVIG, 2013).

Linguagens naturais são ambíguas, podemos toma de exemplo o “Ele viu o banco”, aonde pode significar que ele viu uma peça de mobília ou uma instituição financeira. Com isso não podemos falar de um significado e sim de uma probabilidade sobre o significado(RUSSELL; NORVIG, 2013).

O Processamento de Linguagem Natural (PLN) tal como construído por (JUNIOR, 2008), tem duas abordagens principais, que são a baseada em texto e a baseada em diálogo.

A abordagem baseada em texto tem como principal foco na busca de documentos e resumo e compreensão de textos(JUNIOR, 2008).

A abordagem baseada em diálogo tem crescimento com a interface entre máquinas e humanos(JUNIOR, 2008).

O Processamento de Linguagem Natural tem como principal a etapa de pré-processamento, aonde serão definidas e reconhecidas às sentenças e classificação das palavras a sua função sintática(JUNIOR, 2008).

2.2 Algoritmos de Similaridade

Nesta seção são descritos os algoritmos de similaridade semântica que foram encontrados nos artigos e livros de referência.

2.2.1 Pré-processamento

O pré-processamento é a etapa aonde se pega um texto bruto e o transforma em uma estrutura para os algoritmos usarem, com o principal objetivo de aumentar a qualidade dos dados, considerada à etapa mais onerosa do processo, por não contar com uma única técnica, mas sim por varias técnicas que o constitui(JUNIOR, 2008).

Para a realização do processamento do texto pelos algoritmos existentes é necessário aplicações de algumas técnicas, as principais desses são:

2.2.1.1 *Tokenization*

Tokenization tem como objetivo, a parti de um texto de entrada, a extração de unidades mínimas do texto, sendo o primeiro processo a ser feito no texto de entrada. Cada unidade é chamada de *token*, que normalmente representam uma palavra no texto, mas podem também estar relacionados a mais de uma palavra, símbolo ou caractere de pontuação(JUNIOR, 2008).

Tendo o caractere espaço sempre descartado, uma das abordagens de identificar *tokens* é a quebra do texto em seus delimitadores, como além do espaço: () <>!-?.;'-“|(JUNIOR, 2008).

Entretanto uma tarefa simples de identificar *tokens* simples para um humano pode ser complexo para um algoritmo, temos o exemplo de que o “.” pode ser usado em abreviações ou em números(JUNIOR, 2008).

Uma abordagem descrita por (JUNIOR, 2008) tem os seguintes passos:

- Geração Simples: Utilizando uma lista de delimitadores são extraídos os *tokens* preliminares.
- Identificação de Abreviações: Com a ajuda de dicionários pré-estabelecidos, são identificados os diversos tipos de abreviaturas.
- Identificação de Palavras Combinadas: Algumas palavras compostas, que são interligadas por caracteres como “&” e “-”, devem ser consideradas um único *token*.
- Identificação de Símbolos de Internet: Extraído os endereços de e-mail, endereços de sites (URLs) e endereços IP.
- Identificação de Números: É identificada toda e qualquer forma de apresentação de número, incluindo também medidas e valores, como R$100,00.
- Identificação de Tokens Multivocabulares: Para manter o sentido original de algumas palavras se tem a necessidade de unir elas em um único *token*.

2.2.1.2 Remoção de *stopwords*

As *stopwords* são palavras em um texto que não possuem um valor semântico, são normalmente as preposições, artigos, conjunções, pontuação e pronomes de uma língua. As *stopwords* são removidas de acordo com uma *stoplist*, essa pode ser definida manualmente, tendo as palavras cadastradas manualmente, ou por forma automatizada através da frequência de aparição das palavras, um percentual maior de aparição defini a *stoplist*(JUNIOR, 2008).

2.2.1.3 *Lemmatization*

Lemmatization é o processo de reaver a primitiva de uma palavra, tendo benefício uma estrutura que conserva o sentido das palavras(JUNIOR, 2008).

2.2.2 *Latent Semantic Analysis*(LSA)

Sendo uma técnica matemática e estatística, o *Latent Semantic Analysis(LSA)*, não sendo um processamento de linguagem natural tradicional ele não utiliza qualquer dicionário, redes semânticas ou semelhantes, ele se utiliza do texto puro para a analise.(LANDAUER; FOLTZ; LAHAM, 1998).

Primeiro passo, é representar o texto como uma matriz, aonde cada palavra se torna uma coluna, cada linha é uma trecho de texto, cada célula contém a quantidade de vezes que a palavra se repete no trecho de texto, temos a figura 2 como exemplo.(LANDAUER; FOLTZ; LAHAM, 1998).

É aplicado a decomposição em valores singulares, com isso a matriz é decomposta em no produto de outras três matrizes, são a primeira as linha como vetores de valores de fator ortogonal, a segunda é uma matriz diagonal, a terceira as colunas como vetores de valores de fator ortogonal, a multiplicação dessas se torna nossa matriz inicial(LANDAUER; FOLTZ; LAHAM, 1998), temos a figura 3 como exemplo.

Para finalizar se ordena a matriz S por tamanho, escolhendo os dois maiores valores, assim, pegando as linhas e colunas equivalentes nas matrizes W e P. Com isso se tem uma matriz Xhihat reduzida, é aproximadamente igual a X, com um grau menor(LANDAUER; FOLTZ; LAHAM, 1998), temos a figura 4 como exemplo.

Para o calcula da similaridade (DEERWESTER et al., 1990) descreve as similaridades de comparação de dois termos, é o produto escalar entre os dois vetores linhas da matriz Xhihat, comparação de dois documentos, é o produto escalar entre os duas colunas da matriz Xhihat, e comparação um termo e um documento, é o valor da celular da intersecção da linha e coluna .

Example of text data: Titles of Some Technical Memos

c1: *Human* machine *interface* for ABC *computer* applications
c2: A *survey* of *user* opinion of *computer system response time*
c3: The *EPS user interface* management *system*
c4: *System* and *human system* engineering testing of *EPS*
c5: Relation of *user* perceived *response time* to error measurement

m1: The generation of random, binary, ordered *trees*
m2: The intersection *graph* of paths in *trees*
m3: *Graph minors* IV: Widths of *trees* and well-quasi-ordering
m4: *Graph minors*: A *survey*

$\{X\} =$

	c1	c2	c3	c4	c5	m1	m2	m3	m4
human	1	0	0	1	0	0	0	0	0
interface	1	0	1	0	0	0	0	0	0
computer	1	1	0	0	0	0	0	0	0
user	0	1	1	0	1	0	0	0	0
system	0	1	1	2	0	0	0	0	0
response	0	1	0	0	1	0	0	0	0
time	0	1	0	0	1	0	0	0	0
EPS	0	0	1	1	0	0	0	0	0
survey	0	1	0	0	0	0	0	0	1
trees	0	0	0	0	0	1	1	1	0
graph	0	0	0	0	0	0	1	1	1
minors	0	0	0	0	0	0	0	1	1

Figura 2 – Exemplo da representação do LSA. Fonte:(LANDAUER; FOLTZ; LAHAM, 1998)

Landauer (LANDAUER; FOLTZ; LAHAM, 1998) descreve que o *Latent Semantic Analysis*(LSA) não leva em conta a ordem das palavras no processamento.

Cada célula contendo a quantidade de repetições da palavra é atribuído com .(LANDAUER; FOLTZ; LAHAM, 1998).

É aplicado a decomposição em valores singulares, com isso a matriz é decomposta em no produto de outras três matrizes, são a primeira as linha como vetores de valores de fator ortogonal, a segunda é uma matriz diagonal, a terceira as colunas como vetores de valores de fator ortogonal, a multiplicação dessas se torna nossa matriz inicial(LANDAUER; FOLTZ; LAHAM, 1998).

Landauer (LANDAUER; FOLTZ; LAHAM, 1998) descreve que o *Latent Semantic Analysis(LSA)* não leva em conta a ordem das palavras no processamento.

2.2.3 *STASIS*

Com os avanços nos projetos de linguísticos computacionais, temos bases de conhecimento semântico prontas disponíveis. Essas bases de conhecimento constroem uma hierarquia comum ao mundo, essa hierarquia está ligada as temos "*is a*" ou "*is a kind of*" (ISA), com a ISA podemos determinar a distância semântica entre palavras.

$$\{X\} = \{W\}\{S\}\{P\}'$$

$\{W\} =$

0.22	-0.11	0.29	-0.41	-0.11	-0.34	0.52	-0.06	-0.41
0.20	-0.07	0.14	-0.55	0.28	0.50	-0.07	-0.01	-0.11
0.24	0.04	-0.16	-0.59	-0.11	-0.25	-0.30	0.06	0.49
0.40	0.06	-0.34	0.10	0.33	0.38	0.00	0.00	0.01
0.64	-0.17	0.36	0.33	-0.16	-0.21	-0.17	0.03	0.27
0.27	0.11	-0.43	0.07	0.08	-0.17	0.28	-0.02	-0.05
0.27	0.11	-0.43	0.07	0.08	-0.17	0.28	-0.02	-0.05
0.30	-0.14	0.33	0.19	0.11	0.27	0.03	-0.02	-0.17
0.21	0.27	-0.18	-0.03	-0.54	0.08	-0.47	-0.04	-0.58
0.01	0.49	0.23	0.03	0.59	-0.39	-0.29	0.25	-0.23
0.04	0.62	0.22	0.00	-0.07	0.11	0.16	-0.68	0.23
0.03	0.45	0.14	-0.01	-0.30	0.28	0.34	0.68	0.18

$\{S\} =$

3.34								
	2.54							
		2.35						
			1.64					
				1.50				
					1.31			
						0.85		
							0.56	
								0.36

$\{P\} =$

0.20	0.61	0.46	0.54	0.28	0.00	0.01	0.02	0.08
-0.06	0.17	-0.13	-0.23	0.11	0.19	0.44	0.62	0.53
0.11	-0.50	0.21	0.57	-0.51	0.10	0.19	0.25	0.08
-0.95	-0.03	0.04	0.27	0.15	0.02	0.02	0.01	-0.03
0.05	-0.21	0.38	-0.21	0.33	0.39	0.35	0.15	-0.60
-0.08	-0.26	0.72	-0.37	0.03	-0.30	-0.21	0.00	0.36
0.18	-0.43	-0.24	0.26	0.67	-0.34	-0.15	0.25	0.04
-0.01	0.05	0.01	-0.02	-0.06	0.45	-0.76	0.45	-0.07
-0.06	0.24	0.02	-0.08	-0.26	-0.62	0.02	0.52	-0.45

Figura 3 – Exemplo da representação da decomposição SVD. Fonte:(LANDAUER; FOLTZ; LAHAM, 1998)

$\left\{\hat{X}\right\} =$

	c1	c2	c3	c4	c5	m1	m2	m3	m4
human	0.16	0.40	0.38	0.47	0.18	-0.05	-0.12	-0.16	-0.09
interface	0.14	0.37	0.33	0.40	0.16	-0.03	-0.07	-0.10	-0.04
computer	0.15	0.51	0.36	0.41	0.24	0.02	0.06	0.09	0.12
user	0.26	0.84	0.61	0.70	0.39	0.03	0.08	0.12	0.19
system	0.45	1.23	1.05	1.27	0.56	-0.07	-0.15	-0.21	-0.05
response	0.16	0.58	0.38	0.42	0.28	0.06	0.13	0.19	0.22
time	0.16	0.58	0.38	0.42	0.28	0.06	0.13	0.19	0.22
EPS	0.22	0.55	0.51	0.63	0.24	-0.07	-0.14	-0.20	-0.11
survey	0.10	0.53	0.23	0.21	0.27	0.14	0.31	0.44	0.42
trees	-0.06	0.23	-0.14	-0.27	0.14	0.24	0.55	0.77	0.66
graph	-0.06	0.34	-0.15	-0.30	0.20	0.31	0.69	0.98	0.85
minors	-0.04	0.25	-0.10	-0.21	0.15	0.22	0.50	0.71	0.62

Figura 4 – Exemplo da matriz Xhihat. Fonte:(LANDAUER; FOLTZ; LAHAM, 1998)

Dadas as palavras p1 e p2, podemos encontrar a semelhança semântica através da base de conhecimento, propostos diversos métodos testados por (LI; BANDAR; MCLEAN, 2003), a de melhor desempenho para a semelhança semântica, s(palavra1,palavra2), é uma função entre o comprimento do caminho dos atributos e profundidade.

$$s(palavra1, palavra2) = e^{-al}\frac{e^{bh}-e^{-bh}}{e^{bh}+e^{-bh}}$$

Aonde l é o comprimento do caminho, h a profundidade, e os parametros $a = 0.2$ e $b = 0.6$(LI; BANDAR; MCLEAN, 2003).

Para a similaridade de sentenças descrito por (LI et al., 2006) duas formulas que se completam na formula:

$$s(sentenca1, sentenca2) = \delta\frac{S1\cdot S2}{\|S1\|\cdot\|S2\|} + (1-\delta)\frac{\|r1-r2\|}{\|r1+r1\|}$$

A formula pode ser dividida em duas partes, sendo o δ o peso que defini a importância da ordem das palavras sobre a similaridade das sentenças, dentro de um valor entre (0.5,1], quanto maior o δ menor será a importância da ordem das palavras.(LI et al., 2006)

Para semelhança de sentenças, temos uma frase1 e frase2, fazemos a união dessas, assim não temos palavras repetidas, criamos um vetor S, com o mesmo tamanho da quantidade de palavras da união da frase1 e frase2, ele é preenchido com a função de se a palavra i da União está na frase1, é atribuído 1 em S[i], caso não esteja, é calculado a semelhança da palavra i com cada palavra de frase1, se pega a maior similaridade, e se essa similaridade for maior que um valor predefinido o valor da similaridade é atribuído em S[i], se não é atribuído 0(LI et al., 2006).

Após isso é aplicado um peso para cada S[i], assim S[i]=S[i]*I(palavra i), aonde I(palavra i) $= 1 - \frac{log(n+1)}{log(N+1)}$, N é o número total de palavras no corpus, n é a frequência do palavra i no corpus(LI et al., 2006).

A primeira equação $\frac{S1\cdot S2}{\|S1\|\cdot\|S2\|}$ defini a similaridade com o coeficiente de co-seno entre os dois vectores(LI et al., 2006).

A segunda equação $\frac{\|r1-r2\|}{\|r1+r1\|}$ defini a ordem das palavras como sendo a diferença normalizada da ordem das palavras.(LI et al., 2006). Se temos a frase1={A caixa dentro da cesta} e frase2={A cesta dentro da caixa}, os vetores r1={1,2,3,4,5} e r2={1,5,3,4,2}.

$1 - \frac{\|\{1,2,3,4,5\}\|-\|\{1,5,3,4,2\}\|}{\|\{1,2,3,4,5\}\|+\|\{1,5,3,4,2\}\|} \approx 0.701$

2.3 *Machine Learning*

Como subárea da inteligência artificial, o aprendizado de máquina tem como objetivo criar técnicas computacionais e sistemas automáticamente adquirem conhecimento(REZENDE, 2003).

Como uma ferramenta de aquisição automático de conhecimento, a técnica de *Machine Learning* tem diversos algoritmos que tem diferentes desempenhos para cada problema, sendo importante o compreender suas limitações de desempenho(REZENDE, 2003).

(CARRIJO, 2004) cita as divisões de estratégias de aprendizado de maquina: hábito, instrução, dedução, analogia e indução, considerando a complexidade da inferência, a estratégia de aprendizado por hábito é a mais simples, enquanto que as por analogia e indução são as mais complexas, pois o aprendiz necessita de um maior esforço para o aprendizado.

Na figura 5, podemos ver a hierarquia do aprendizado focando o caminho que leva a classificação.

> Aprendizado indutivo é efetuado a partir de raciocínio sobre exemplos fornecidos por um processo externo ao sistema de aprendizado. O aprendizado indutivo pode ser dividido em supervisionado e não-supervisionado. No aprendizado supervisionado é fornecido ao algoritmo de aprendizado, ou indutor, um conjunto de exemplos de treinamento para os quais o rótulo da classe associada é conhecido(REZENDE, 2003).

Os exemplos usados para a indução são em geral descritos por vetores de valores, aonde cada valor representa uma característica ou atributos, e um rótulo da classe associada, com isso o algoritmo de indução tenta classificar novos exemplos em suas devidas classes, para os rótulos de classe discretos, esse problema é conhecido como classificação e para valores contínuos como regressão(REZENDE, 2003).

Para o aprendizado não supervisionado temos que o indutor irá analisar e agrupar os exemplos, de alguma maneira utilizando de medida de similaridade, com isso após o agrupamento é necessário uma interpretação dos agrupamentos para saber seu significado(CARRIJO, 2004).

Outro fator é o esclarecimento das classificações, em (MICHALSKI; BRATKO; KUBAT, 1998) são divididos em dois tipos de sistemas de aprendizado:

- Sistemas considerados caixa-preta, tem representações de conceitos que não são interpretadas com facilidade por humanos, não fornecendo nem explicando o processo de reconhecimento.

- Sistemas voltados a conhecimento, tem estruturas para a compreensão do conhecimento por humanos.

Na Tabela 1 são resumidas por (REZENDE, 2003) as características gerais dos sistemas de Aprendizado de Máquina.

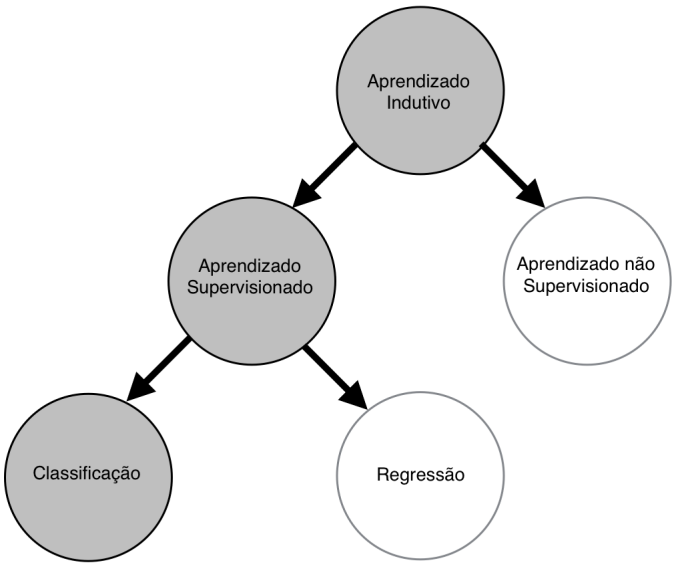

Figura 5 – Hierarquia do aprendizado

Tabela 1 – Características gerais de sistemas de Aprendizado de Máquina

Modos de formas de aprendizado	Paradigmas de Aprendizado	Formas de Aprendizado
Supervisionado Não Supervisionado	Simbólico Estatístico Baseado em instâncias Conexionista Genético	Incremental Não Incremental

2.3.1 Aprendizado Supervisionado Conceitos e Definições

Nessa seção são descritos algumas definições de termos e problemas de classificação no aprendizado supervisionado definidos por (REZENDE, 2003) e (CARRIJO, 2004):

Indutor: O objetivo do indutor é enontrar um classificador com base em conjunto de exemplos rotulados.

Exemplo: O exemplo descerve o objeto de interese na forma de valores em um vetor.

Atributo: Descreve características de um exemplo, existem ao menos dois tipos de atributos são eles o nominal ou discreto, quando não existe uma ordem entre os valores e contínuo, quando existe uma ordem entre valores.

Existem também símbolos especiais para os atributos, são eles o de ausência do atributo, que é diferente de zero, normalmente representado pelo símbolo “?”, e o não-se-aplica, quando um atributo não se aplica ao exemplo, normalmente representado pelo símbolo “!”.

Classe: No aprendizado supervisionado o exemplo possui um atributo especial,

chamado de rótulo ou classe, que descreve o fenômeno de interesse, isso é a meta que se deseja aprender para fazer previsões, tipicamente pertencentes a um conjunto discreto (nominal) de classes C1, C2, ..., Ck no caso de classificação ou de valores reais no caso de regressão.

Conjunto de Exemplos: Um conjunto de exemplos é composto por exemplos contendo valores de atributos bem como a classe associada. Na Tabela 2 é mostrado o formato padrão de um conjunto de exemplos T com n exemplos e m atributos. Nessa tabela está representado um conjunto de dados com N exemplos e M atributos. Nesse formato, as colunas (X1, ..., Xm) representam os diferentes atributos e as linhas (T1, ..., Tn) os diferentes exemplos, na ultima coluna temos o Y, yi = f(x_1, ..., xn), é a função que se tenta predizer a partir dos atributos.

Ruído: Um ruído pode ser causado por diversas coisas, pelo próprio processo de aquisição dos dados, transporte dos dados, entre outros, com isso temos o exemplo de dois exemplos com atributos iguais e classes diferentes, isso é um ruído.

Conhecimento do Domínio: É o conhecimento prévio sobre o domínio trabalhado, como limites ou valores válidos para atributos, nem todos os indutores são capazes de usar o conhecimento do domínio, eles usam apenas os exemplos fornecidos.

Classificador: Como falado acima, um indutor gera como saída um classificador, de forma a dado uma entrada não rotulada possa classifica-la com maior precisão possível sua classe. A tarefa de um indutor é, dado um conjunto de exemplos, induzir uma função h que aproxima f, normalmente desconhecida, onde h(xi) aproximasse de f(xi)

Bias: Qualquer escolha de hipótese além da consistência dos exemplos se chama de *bias* de aprendizado. Devido ao fato que quase sempre existe um número grande de hipóteses consistentes, todos os indutores possuem alguma forma de *bias*(MITCHELL, 1997).

Modo de Aprendizado: Dividido em dois modos, o não-incremental necessita de todo o conjunto de treinamento para o aprendizado, conhecido como *batch*, o incremental o indutor tenta atualizar a função h, sempre que novos exemplos são adicionados ao conjunto de treinamento.

Espaço de descrição: Cada atributo xij corresponde a uma coordenada em um espaço de m dimensões, cada ponto no espaço tem uma classe associada de yi, com isso o classificador divide este espaço em regiões, e cada região rotulada com uma classe. Quando um novo exemplo é classificado é determinado seu ponto no espaço e atribuído a classe daquela região.

Erro de precisão: É uma medida de desempenho dada ao classificador, ou taxa de classificação incorreta, para isso se usa a formula erro(h):

Tabela 2 – Conjunto de exemplos no formato atributo-valor

	X1	X2	...	Xm	Y
T1	x11	x12	...	x1m	y1
T2	x21	x22		x2m	y2
...	...	...	...	...	...
Tn	xn1	xn2	...	xnm	yn

$erro(h) = \frac{1}{n} \sum_{i=1}^{n} \parallel yi \neq h(xi) \parallel$

O operador ‖ E ‖ retorna 1 se a expressão for verdadeira e 0 se falso, complementando a taxa de erro o acc(h) é a precisão:

$acc(h) = 1 - erro(h)$

Para problemas de regressão o erro(h), pode ser calculado pela distância do valor real para o valor dado de classificador. São dadas duas equações, sendo elas o erro médio quadrado (mse-err ou mean squared error) e a distância absoluta média (mad-err ou mean absolute distance), apresentadas como:

$mse - err(h) = \frac{1}{n} \sum_{i=1}^{n} (yi - h(xi))^2$

$mad - err(h) = \frac{1}{n} \sum_{i=1}^{n} \mid yi - h(xi) \mid$

Distribuição de classes: Dada um conjunto de T exemplos, a distribuição de classes da a porcentagem de cada classe sobre o modelo, dada pela formula distribuicao(Cj), aonde Cj é parte do conjunto T, e n o total de exemplos:

$distribuicao(Cj) = \frac{1}{n} \sum_{i=1}^{n} \parallel yi = Cj \parallel$

Como exemplo temos que em um conjunto de 100 exemplos, temos as classes C1 com 60 elementos, C2 com 30 elementos e C3 com 10 elementos, a distribuição ficaria distribuicao(C1,C2,C3)=(0,60, 0,30, 0,10) = (60,00%, 30,00%, 10,00%), a C1 se define como classe majoritária e o C2 se define como classe minoritária.

Erro majoritária:É o erro máximo que um pode cometer classificador, sua formula:

$maj - err(T) = 1 - max(distribuicao(C1, .., Cn))$

No exemplo acima o erro majoritário é maj-err(T) = 1 - 0,60 = 40,00%.

Prevalência de classes: Quando uma classe tem uma alta classificação gera um desbalanceamento do conjunto de exemplos, como exemplo a distribuicao(C1,C2,C3)=(98%, 1,0%, 1,0%) de um classificador, que classifique exemplos como pertencentes à classe majoritária C1 teria uma precisão de 98,00% (maj-err(T) = 2,00%).

Under* e *Overfitting: Ao induzir uma hipótese a partir de um conjunto de exemplos podemos ter que essa seja muito especifica para esse conjunto. O exemplo é uma parte do conjunto domínio, é possível induzir hipóteses que melhorem o conjunto de

treinamento, quando a hipótese se ajusta ao treinamento e seu desempenho piora com exemplos diferentes ouve um *overfitting* ou seja ajustou-se em excesso ao conjunto de treinamento.

O contrário de um *overfitting*, seria quando um conjunto muito pequeno de exemplos fazendo a hipótese se ajustar pouco ao conjunto de testes gerando um *underfitting*.

Overtuning: O excesso de ajustes, para que todos os parâmetros sejam otimizados para todos os exemplos se chama *Overtuning*, assim com o *overfitting*, pode ser evitado utilizando-se apenas uma parte dos exemplos disponíveis para a execução do indutor e o restante dos exemplos para um teste final do classificador induzido. Os exemplos agrupados em conjuntos de treinamento e teste, uma vez treinado se aplica os exemplos de testes, para avaliar a confiabilidade das estimativas futuras do sistema.

Poda: A poda é um método que se usa para lidar com o ruído e *overfitting*, há dois métodos para a poda, o pré-poda, são removidos alguns exemplos antes da geração da hipótese, pós-poda, uma hipótese e gerada e algumas partes eliminadas.

Completude e Consistência: Uma hipótese pode ser avaliada em duas formas, a completude, se ela classifica todos os eventos, e a consistência, se classifica corretamente os exemplos, temos quatro combinações possíveis, são elas (a) completa e consistente; (b) incompleta e consistente; (c) completa e inconsistente ou (d) incompleta e inconsistente. Temos na figura 6 um exemplo considerando dois atributos X1 e X2, três classes, bola azul, adição azul, e asterisco verde, as hipóteses induzidas para cada classe são representadas por duas regiões indicadas por linhas sólidas para a classe bola azul, duas regiões indicadas por linhas pontilhadas para a classe adição vermelha e uma região indicada por linhas tracejadas para a classe asterisco verde.

Matriz de confusão: Ela é uma forma de medir a efetividade do modelo, aonde mostrar o número de classificações corretas versus as classificações preditas para cada classe, sobre um conjunto de exemplos T. Como na tabela 3, temos K classes verdadeiras e K classes preditas, cada elemento representa o número de exemplos em T, que pertenciam a Ci, mas foram classificados como Cj, calculado por:

$$M(Ci, Cj) = \sum_{\forall(x,y)\in T: y=Ci} \parallel h(x) = Cj \parallel$$

O número de acertos, para cada classe, se localiza na diagonal principal M(Ci,Ci) da matriz, os demais elementos M(Ci,Cj), para i $\neq$ j, representam erros na classificação. A matriz de confusão de um classificador ideal possui todos esses elementos que não são da diagonal principal iguais à zero, podendo ser representado por uma matriz identidade multiplicado por um vetor contendo as quantidade de (C1,C2..., Ck).

Custo de erro: O custo do erro, representado por cost(Ci,Cj), é a penalidade aplicada ao classificador que classifica um exemplo em Ci, quando deveria classificar como Cj, assim o cost(Ci,Ci) = 0, uma vez que não é um erro, logo cost(Ci,Cj) > 0, para i $\neq$j,

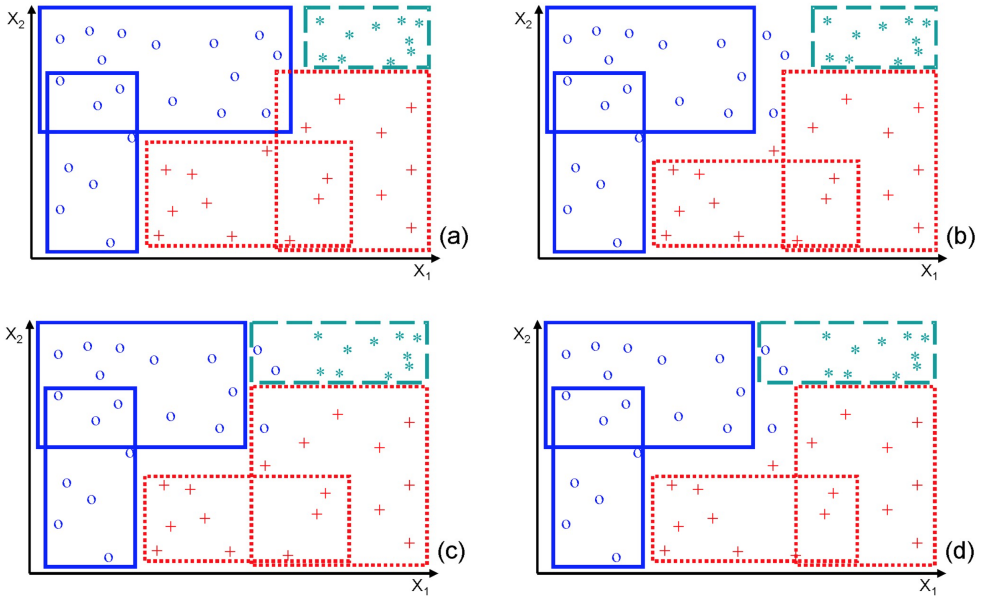

Figura 6 – Completude e consistência de uma hipótese. Fonte:(REZENDE, 2003)

Tabela 3 – Matriz de confusão de um classificador

Classe	predita C1	...	predita Ck
Verdadeira C1	M(C1,C1)	...	M(C1,Ck)
...	...	...	...
Verdadeira Ck	M(Ck,C1)	xn2	M(Ck,Ck)

em geral é dado cost(Ci,Cj) = 1. No calculo do custo os erros são convertidos em custos pela multiplicação do erro pelo custo correspondente, pela formula:

$$errocost(h) = \frac{1}{n} \sum_{i=1}^{n} \parallel yi \neq h(xi) \parallel Xcost(yi, h(xi)$$

Também pode ser obtido pela matriz de confusão, pela formula:

$$errocost(h) = \frac{1}{n} \sum_{i=1}^{n} \sum_{j=1}^{n} M(Ci, Cj) Xcost(Ci, Cj)$$

Complexo: É uma disjunção de conjunções para testar atributos, tendo a forma de X operador Valor, aonde X é um atributo, operador é um operador pertencente ao conjunto $=, \neq, >, <, \geq, \leq$ e Valor é um valor constante válido para o atributo X, retornando verdadeirou ou falso.

Regra: Uma regra assume a forma se L então R, podendo ser escrita como $L \rightarrow R$, normalmente L e R são complexos e sem atributos em comum. A parte esquerda L é denominada condição, premissa, cauda ou corpo da regra, e a parte direita R é denominada conclusão ou cabeça da regra.

Regra de Classificação: Uma regra de classificação assume a forma de uma regra se L então classe = Ci, onde Ci pertence ao conjunto de K valores de classe C1, ..., Ck.

Cobertura: A cobertura de uma regra $L \rightarrow R$, pode ser descrita por quatro esta-

dos, exemplos que cumprem a parte L da regra constituem o seu conjunto de cobertura, exemplos que cumprem tanto a condição L como a conclusão R são inclusos pela regra, exemplos que cumprem a condição L mas não a conclusão R são inclusos incorretamente pela regra e os exemplos que não cumprem a condição L não são inclusos pela regra.

2.4 Algoritmo genético

Carrijo (CARRIJO, 2004) divide os períodos do desenvolvimento de inteligência artificial em quatro fases, são elas:

- Período sub-simbólico, entre 1950 e 1965, tinha como principal característica a representação do conhecimento de forma numérica.
- Período simbólico, entre 1962 e 1975, tinha como principal característica o desenvolvimento dos algoritmos de representações simbólicas como a Lógica de Predicados e Redes Semânticas.
- Período intensivo, entre 1976 e 1988, tinha como principal característica a quantidade de conhecimentos que era incorporados aos sistemas de aprendizagem.
- Atualmente, tem como característica tornar o computador *expert* no desenvolvimento de determinadas tarefas.

2.4.1 Terminologia

A área de algoritmos genéticos existem termos que são voltados a biologia, abaixo existe a explicação dos principais, citados por (GOLDBERG, 1989 apud CARRIJO, 2004) (GALVAO, 1999 apud CARRIJO, 2004) (MICHALEWICZ; ATTIA, 1994 apud CARRIJO, 2004):

- Cromossomo ou Genoma: Representa a estrutura de dados compostas por genes, que codifica uma solução para um problema.
- Gene: Sendo uma característica do cromossomo, representa uma variável que de decisão do problema em um vetor que representa o Cromossomo.
- Indivíduo: É representado pelo seu cromossomo e valor de aptidão.

2.4.2 O algoritmo

O processo do Algoritmo genético foi descrito por Holland é conhecido na literatura como *Simple Genetic Algorithm ou Standard Genetic Algorithm* ou, simplesmente, SGA,

descrito por (DAVIS, 1991 apud CARRIJO, 2004), são seis passos simples, A figura 7 mostra um fluxograma com os passos básicos de um algoritmo genético *standard*:

1. Inicia a população de tamanho fixo N.
2. Avalie a função de aptidão para cada solução dessa população.
3. Cria novos cromossomos(filhos) através de recombinação da população atual(pais).
4. Elimine membros da antiga população, para inserir os filhas, mantendo o número fixo N da população.
5. Aplique-se a função de aptidão nos novos filhos e os coloca na população.
6. Verifica a condição de parada, podendo ser encontrou a solução ideal, um número pré-estabelecido de gerações foram criadas, e retorna a solução com a melhor aptidão. Caso contrário, volte ao passo três.

2.4.2.1 Iniciação da população

Seguindo a metodologia do algoritmo temos o primeiro passo, a iniciação, descrita por (SILVA, 2005), ela pode ser de três maneiras:

- Inicialização Aleatória: Os indivíduos da população são gerados de forma aleatória.
- Inicialização Determinística : Os indivíduos da população são gerados segindo uma função predeterminada.
- Inicialização Aleatória com Nicho: Os indivíduos da população são gerados com características semelhantes.

A iniciação não necessariamente precisa ser aleatória, podendo ser gerado uma população em um intervalo aonde se acredita ter a resposta, ou podemos ter um escalonador para a população, tendo como exemplo uma população de 50 indivíduos distribuídos igualmente entre 0 a 10(SILVA, 2005).

2.4.2.2 Seleção dos Pais

Para a seleção dos pais são usadas a Função de aptidão e Métodos de seleção.

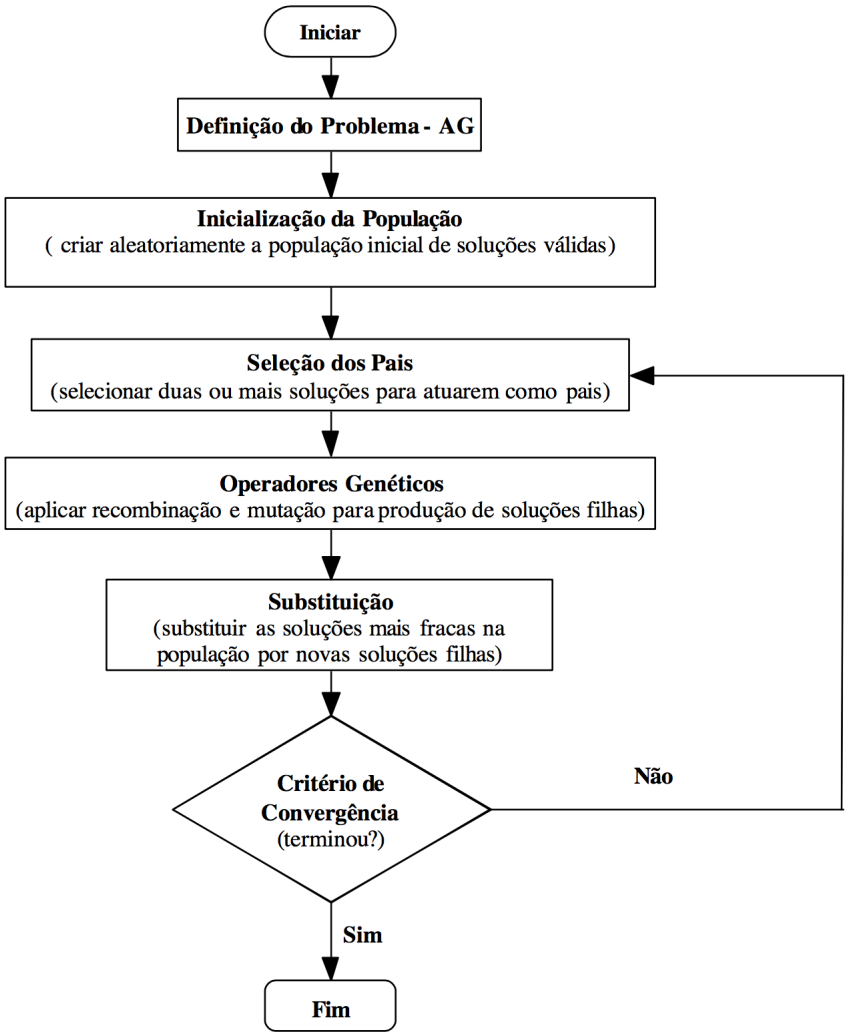

Figura 7 – Fluxograma do algoritmo genético *standard*. Fonte:(CARRIJO, 2004)

2.4.2.3 Função de aptidão

Uma função de aptidão é o que liga o código a solução, toma como entrada um cromossomo, que é uma tentativa de resolver o problema, e retorna um número real que informa o desempenho dele, esse valor é usado no processo de seleção e reprodução(CARRIJO, 2004).

Para a seleção ao selecionar os indivíduos mais aptos, após a passagem desses pela função de aptidão, para alguns métodos é desejável que a soma dos valores de aptidão seja 1, para isso pode ser usado a formula abaixo, que é a aptidão relativa:(SILVA, 2005)

$$f(x_i)_{rel} = \frac{f(x_i)}{\sum_{j=1}^{n} f(x_j)}$$

Aonde X_i é um cromossomo, $f(x_i)$ é a função de aptidão e $f(x_i)_{rel}$ é o valor relativo dele.

Tabela 4 – Exemplo de seleção pelo método da roleta(SILVA, 2005)

Indivíduo	Aptidão	Roleta	Aptidão Relativa	Porcentagem
I1	22	22	0.27160493	27%
I2	25	47	0.30864197	31%
I3	17	64	0.20987654	21%
I4	7	71	0.08641975	9%
I5	10	81	0.12345679	12%

2.4.2.4 Métodos de seleção

Os métodos de seleção, tem a proposta de procurar favorecer os indivíduos mais aptos, mas tentando manter a diversidade, citados por (SILVA, 2005) temos os:

- Roleta.
- Torneio.
- Amostragem estocástica.

2.4.2.4.1 Roleta

Esse é o método mais simples descrito, e normalmente o mais utilizado, os indivíduos são representados como uma roleta, seu espaço é proporcional ao número dado pela função de aptidão a ele, com isso são gerados números aleatórios entre 0 e o total do somatório da aptidão, o número de vezes gerado depende do tamanho da população, indivíduos selecionados são inseridos na população intermediária(SILVA, 2005).

Na figura 8 e na tabela 4 temos um exemplo referente ao uso do método (SILVA, 2005):

2.4.2.4.2 Torneio

Os indivíduos são separados em grupos com n indivíduos, o melhor de cada grupo é selecionado para a população intermediaria, geralmente o n é usado como três. Exemplo na figura 9 (SILVA, 2005).

2.4.2.4.3 Amostragem Estocástica

É uma variação do método da roleta, ao em vez de se rodar a roleta a quantidade de vezes necessárias, é dado o número n necessário aonde é dividido igualmente seu espaço a parti do ponto escolhido, com isso só é necessário uma rodada(SILVA, 2005).

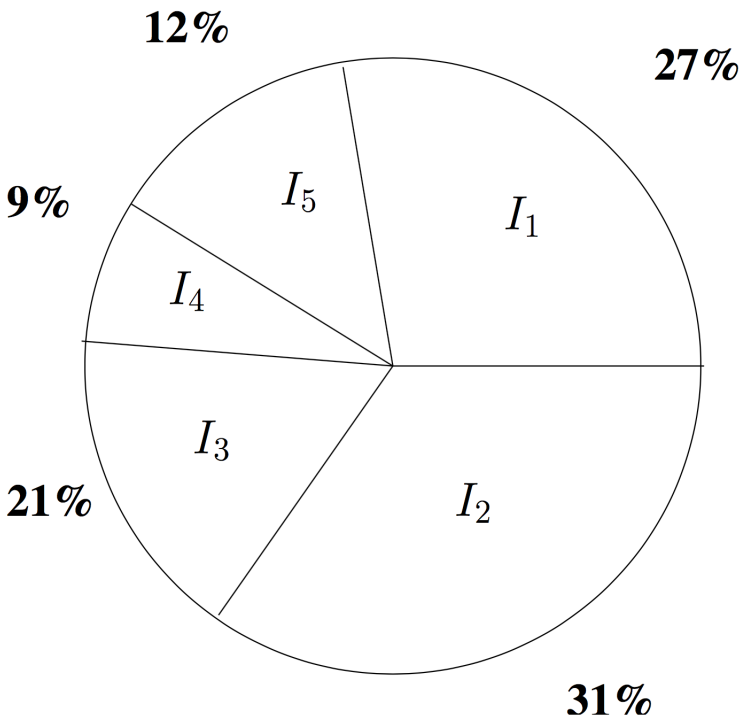

Figura 8 – Esquema da Roleta. Fonte:(SILVA, 2005)

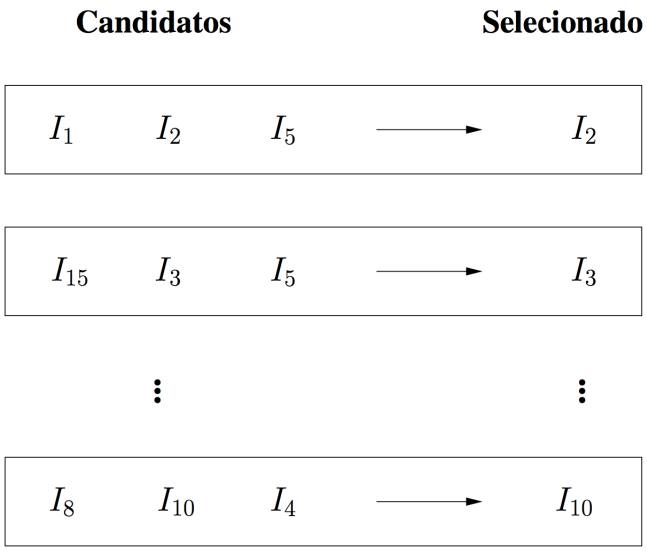

Figura 9 – Esquema do Torneio. Fonte:(SILVA, 2005)

2.4.2.5 Operadores Genéticos

As operações genéticas descritas por (SILVA, 2005) e (CARRIJO, 2004) são:

- Cruzamento, Recombinação ou *Crossover*.
- Mutação.

2.4.2.5.1 Cruzamento, Recombinação ou *Crossover*

Geralmente usando uma permutação simples entre os pais, ou da combinação entre características correspondentes entre soluções pais, o primeiro caso é mais usado em representadas através de código binário, enquanto o segundo no caso de representação real das soluções(CARRIJO, 2004).

A recombinação é dada por uma probabilidade denominada de taxa de recombinação, que varia entre 60% e 100%. Isso implica que os filhos podem ser iguais aos pais, gerando um número entre [0,1], podemos sortear quais seriam permutados ou não(CARRIJO, 2004).

Seguindo os seguintes passos descritos por (CARRIJO, 2004), podendo ser visto na figura 10:

- Gera-se um número aleatório entre 0 e 1.
- Se o número gerado for maior ou igual à probabilidade de recombinação, ocorrer recombinação, caso não seja não ocorrerá recombinação.
- Escolhe-se, aleatoriamente um ponto, no qual ocorrerá a quebra.
- Quebram-se os dois cromossomos neste ponto.
- Formam-se dois novos cromossomos combinando-se a primeira parte do cromossomo A com a segunda parte do cromossomo B, e a primeira parte do cromossomo B com a segunda parte do cromossomo A.

2.4.2.5.2 Mutação

O processo de mutação geralmente controlado por um fator de porcentagem, que que indica a probabilidade de um gene sofrer mutação. Com isso é inserido novo material genético em cada geração(CARRIJO, 2004) (SILVA, 2005).

A operação de mutação pode ser aplicada antes ou depois da recombinação, a operação de mutação percorre todos os bits ou genes da solução e com uma probabilidade predeterminado de o gene ser trocado ou não, probabilidade de afetar um gene deve ser definida de forma que seja bem pequena, para não causar destruição de um cromossomo(CARRIJO, 2004).

2.4.2.6 Subistituição

Elimine membros da antiga população, para inserir os filhas, mantendo o número fixo N da população.(DAVIS, 1991 apud CARRIJO, 2004).

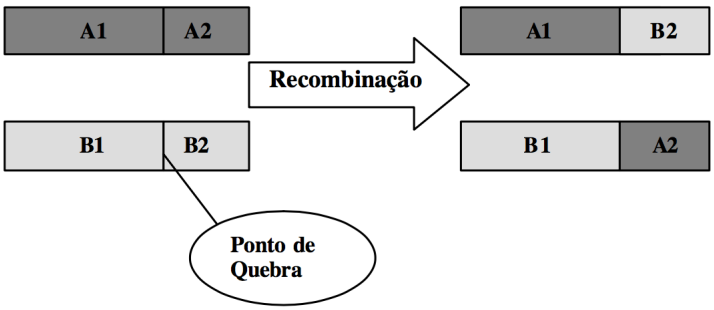

Pais: **(recombinação após o oitavo bit)** **Filhos:**

1 1 1 1 1 1 1 1 | 1 1 1 ---------- **1 1 1 1 1 1 1 0 0 0**
0 0 0 0 0 0 0 0 | 0 0 0 ---------- 0 0 0 0 0 0 0 **1 1 1**

Pais: **(recombinação após o segundo bit)** **Filhos:**

1 0 | 1 1 0 1 0 0 0 1 ---------- **1 0** 0 1 1 0 0 0 1 1
1 1 | 0 1 1 0 0 0 1 1 ---------- 1 1 **1 1 0 1 0 0 0 1**

Figura 10 – Esquemas de uma recombinação simples. Fonte:(CARRIJO, 2004)

2.4.2.7 Parâmetros Genéticos

Descritos por (SILVA, 2005) e (CARRIJO, 2004) são listados alguns parâmetros usados em Algoritmos genéticos, são eles:

- Tamanho da População.
- Taxa de Cruzamento.
- Taxa de Mutação.
- Taxa de Substituição.
- Critérios de parada.
- Problemas de convergência.

2.4.2.7.1 Tamanho da População

Com uma população grande pode afetar o desempenho geral do sistema, assim como uma população pequena pode não ter uma cobertura boa do espaço da busca do problema, uma grande população nos dar uma grande cobertura do espaço de busca da solução, além de evitar a escolha de uma máximo local, ao em vez do máximo global, no entanto há necessidade de recursos computacionais mais poderosos ou de maior tempo para processamento.

2.4.2.7.2 Taxa de cruzamento

Uma taxa de cruzamento alta, poderá retirar estruturas com boas aptidões, uma tava de cruzamento baixa, o algoritmo poderá ficar lento ou trava.

2.4.2.7.3 Taxa de Mutação

Uma taxa baixa de mutação nos previne perda de cromossomos com uma boa aptidão, e previne também a estagnação, um fator muito grade de mutação faz nossa busca ser essencialmente aleatória.

2.4.2.7.4 Taxa de Substituição

É a taxa que será substituída a geração anterior, com uma taxa alta pode ocorrer perda de população com alta aptidão, um valor baixo pode tornar o algoritmo lento.

2.4.2.7.5 Critérios de parada

Como critérios de parada se usam normalmente um número máximo de gerações, tempo de processamento ou uma estagnação da melhoria, isso é mínimas variação dos valores da aptidão ou do melhor membro ou da população.

2.4.2.7.6 Problema de Convergência

A convergência prematura é um problema comum em Algoritmos genéticos, ocorre quando são achados soluções com aptidão elevada, mas não ótimas, com isso esses cromossomos podem dominar a população, esse problema pode ser evitado limitando o numero de filhos por cromossomo, pode-se também aumentar a taxa de mutação para aumentar a diversidade ou evitar inserir filhos duplicados.

2.5 Engenharia de Software

2.5.1 Metodologia Scrum

O SCRUM é um *framework* desenvolvido por Ken Schwaber e Jeff Sutherland, usado desde 1990 para o gerenciar o desenvolvimento de produtos complexos, ele tenta entregar produtos com o maior valor agregado possível(SCHWABER; SUTHERLAND, 2013).

Os times, que estão associados a papeis, eventos, artefatos e regras, seu fundamento vem o empirismo, ou seja a experiência gera o conhecimento, utilizando o interativo e incremental para adequar as previsões e controle de riscos(SCHWABER; SUTHERLAND, 2013).

Segundo (SCHWABER; SUTHERLAND, 2013) os três pilares que sustentam o SCRUM são: transparência, inspeção e adaptação.

Transparência: Sempre manter visível os resultados aos interessados, requerendo um padrão comum para que todos os observadores possam ter o mesmo ponto de vista.

Inspeção: Sendo benéficas quando realizadas de forma correta, devesse frequentemente se inspecionar os artefatos desde que não atrapalhe a real trabalho, sendo melhor realizadas por especialistas em suas áreas.

Adaptação: Uma vez encontro, através de inspeções, um erro ou desvio dos limites aceitáveis em qualquer artefato, devesse ajustar o mesmo o mais cedo possível para minimizar maiores desvios.

Formalmente se tem quatro eventos envolvendo o inspeção e a adaptação(SCHWABER; SUTHERLAND, 2013):

- Reunião de planejamento da *Sprint*.
- Reunião diária.
- Reunião de revisão da *Sprint*.
- Retrospectiva da *Sprint*.

2.5.1.1 O time Scrum

O time Scrum se auto-organiza, tendo autonomia para escolher a melhor forma de trabalhar, e é multifuncional, aonde pode completar qualquer tarefa independente de outros fora da equipe. Três parte distintas se envolvem no time Scrum são essas *Product Owner*, o Time de Desenvolvimento e o *Scrum Master*(SCHWABER; SUTHERLAND, 2013).

Product Owner: Responsável por manter os itens no *backlog* do produto, tornando ele visível e claro a todos, garantindo que o time de desenvolvimento entenda-os. O *Product Owner* é representado por uma pessoa.

Time de Desenvolvimento: Tem como principal função transforma o *backlog* do produto em incrementos funcionais para o cliente, tento ele todos os requisitos para o desenvolvimento dos item *backlog* do produto, sem dependência externa, no time todos são desenvolvedores, não podendo ter outros títulos ou agrupamentos de sub-times com especializações.

Scrum Master: Sendo o responsável pelo cumprimento das praticas do Scrum, trabalha nos âmbitos, com o *Product Owner*, esclarecendo os itens no *backlog* do produto, compreender o projeto a longo-prazo e facilitando os eventos do Scrum, com o Time de desenvolvimento, liderando o time nas praticas de agregar o maior valor de produto, autogerenciamento e Scrum, além de ser o facilitador de impedimentos do time.

2.5.1.2 Eventos do Scrum

No Scrum todos os eventos são *time-boxed*, isso é tem um tempo fixo máximo para duração, cada evento foi criado para ser possível a realização da transparência e inspeção(SCHWABER; SUTHERLAND, 2013).

2.5.1.2.1 *Sprint*

No Scrum a *Sprint* é o principal evento, que engloba todos os demais, de forma que o tempo dela é fixo não podendo ser alterado posteriormente, com um limite de um mês, sendo que uma *Sprint* começa assim que termina a anterior, compostas por uma reunião de planejamento da *Sprint*, reuniões diárias, trabalho de desenvolvimento, uma revisão da *Sprint* e a retrospectiva da *Sprint*(SCHWABER; SUTHERLAND, 2013).

2.5.1.2.2 Reunião de Planejamento da *Sprint*

Todo trabalho a ser realizado na *Sprint* é definido nesta reunião, com um limite de oito horas para um *Sprint* de um mês, com dois tópicos que são (SCHWABER; SUTHERLAND, 2013):

- Quais incrementos podem ser entregues na próxima *Sprint*?
- Como será realizado o trabalho para incremento?

Ao responder essas questões se tem meta da *Sprint*, que guia o time de desenvolvimento para a construção de algo de valor ao cliente, a parti dos itens escolhidos a

serem feitos na *Sprint* se cria o *backlog* da *Sprint*, que será desenvolvido(SCHWABER; SUTHERLAND, 2013).

2.5.1.2.3 Revisão da *Sprint*

Essa reunião inclui todos envolvidos no Scrum tendo um *time-boxed* de quatro horas, são os principais itens de pauta da reunião, a apresentação dos itens do *backlog* que foram definidos pelo *Product Owner* que estão prontos e os que não estão prontos, o time de desenvolvimento demostra o que está pronto e responde as duvidas sofre o incremento, análise de possíveis mudanças no mercado.

2.5.1.3 Artefatos do Scrum

2.5.1.3.1 *Backlog* do Produto

Onde se encontra uma lista de tudo que é necessário para o desenvolvimento do sistema, o *Backlog* do Produto evolui junto com o projeto e o desenvolvimento(SCHWABER; SUTHERLAND, 2013).

2.5.1.3.2 *Backlog* da *Sprint*

Onde se encontra os itens selecionados do *Backlog* do Produto para se desenvolver no período da *Sprint*(SCHWABER; SUTHERLAND, 2013).

2.5.2 Arquitetura *Model View Controller*(MVC)

Segundo (KRASNER; POPE, 1988) o MVC é dividido em três camadas, sendo *Model*, é uma simulação do domínio especificação, podendo ser um simples digito a um objeto complexo, *View*, solicita dados da *Model*, contendo as informações visuais e os componentes necessários para a exibição, *Controller*, é a responsável por capturar ações de dispositivos de entrada, e com isso conectar as chamadas entre a *Model* e *View*.

O MVC tem o ciclo começo por uma ação do usuário, a *Controller* notifica a *Model*, para que seu estado seja atualizado, a *Model* efetua as modificações necessárias e alerta as suas depenicas que foi alterada, assim a *View* consulta o novo estado da *Model*, e atualiza a sua visualização, temos a figura 11 como exemplo desse ciclo(KRASNER; POPE, 1988).

2.5.3 Paradigma Orientado a Objetos

Permitindo o tratamento de substantivos como objetos e verbos como ações, um objeto pode ser um ator, agente ou servidor, podemos definir um objeto como uma entidade que (BOOCH, 1986):

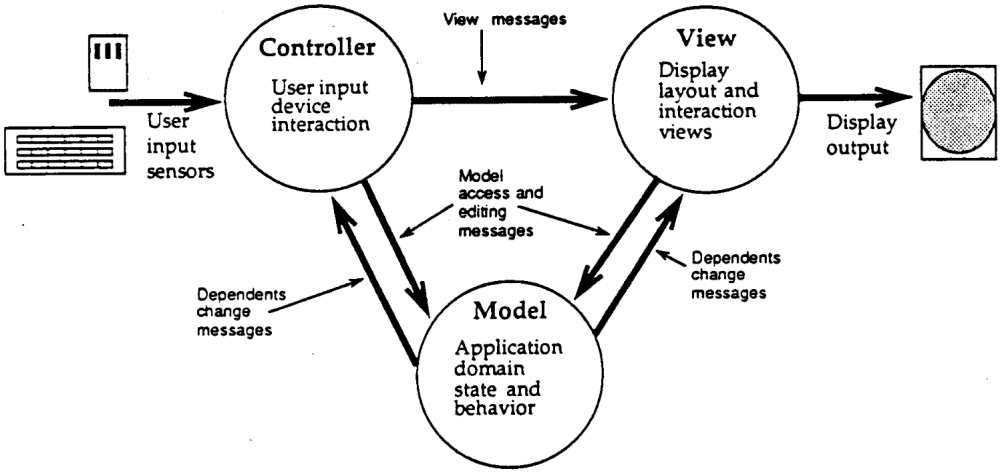

Figura 11 – Ciclo de interação do MVC. Fonte:(KRASNER; POPE, 1988)

- Tem estado.
- Sobre ações de outros objetos.
- É uma instância de classe.
- É expresso por um nome.
- Restringe visibilidade para outros objetos.

Se descreve os seguintes passos para se desenvolver um objeto (BOOCH, 1986):

- Identificar seus atributos.
- Identificar suas operações.
- Estabelecer a visibilidade do objeto.
- Estabelecer a interface.
- Implementar o objeto.

3 A PROPOSTA

Neste capítulo é descrita a proposta do trabalho, detalhando os passos a serem realizados e considerando o referencial teórico apresentado e estudos já realizados.

3.1 Introdução

Com a evolução da tecnologia, os computadores se tornaram cada vez mais parte do nosso cotidiano, com as mais diversas utilidades, desde cálculos complexos e previsão do tempo, diversão, comunicação, educação entre outros, com isso o computador se tornou algo fundamental na sociedade.

Para a educação a utilização cada vez maior de Ambientes virtuais de aprendizado (AVA), que podem ser usados tanto para alunos de cursos presenciais ou de educação a distância (EAD), melhora o acompanhamento pelo professor, que tem a possibilidade de oferecer as matérias de estudo, recolher atividades, aplicar testes entre outras atividades oferecidas.

Nesse trabalho iremos focar a parte de avaliação, nas AVA's podem-se ter avaliações por meio de perguntas de múltipla escolha, verdadeiro ou falso entre outros, a avaliação de questões discursivas pode ser realizada, mas sua correção tem que ser feita manualmente, assim com processamento de linguagem natural (PLN), uma subárea da inteligência artificial, poderá ser usada para a realização de uma pré-avaliação de questões discursivas de forma a guiar os tutores na correção, que ele poderá aceitar ou dar a nota que ele achar correta.

A proposta é desenvolver uma forma de analisar a resposta discursiva com um gabarito definido, com algoritmos de similaridade de texto como *latent semantic analysis* (LSA) e STASIS, podemos comprará o quanto que dois textos são similares e através dessa ter uma nota de similaridade, além dessa análise, uma vez que o tutor der uma nota que não seja a proposta pelo sistema, um algoritmo genético irá analisar quais elementos do texto implicou na diferença na nota, com essa diferença armazenada o sistema aprende qual parte do texto deverá ter maior ou menor nota e quais partes do texto não fazem parte do gabarito inicialmente definido que também alteram a nota final, para que na próxima vez que for aplicada essa pergunta já ter novos pesos.

3.2 O processo

O processo da figura 12 foi estabelecido em fases, são elas: Inserir o exame, Treinamento do sistema, Disponibilizar exame, Responder exame, Correção das respostas enviadas, Correção das respostas pelo tutor, Disponibilizar notas, Recurso por parte do aluno e Responder recurso.

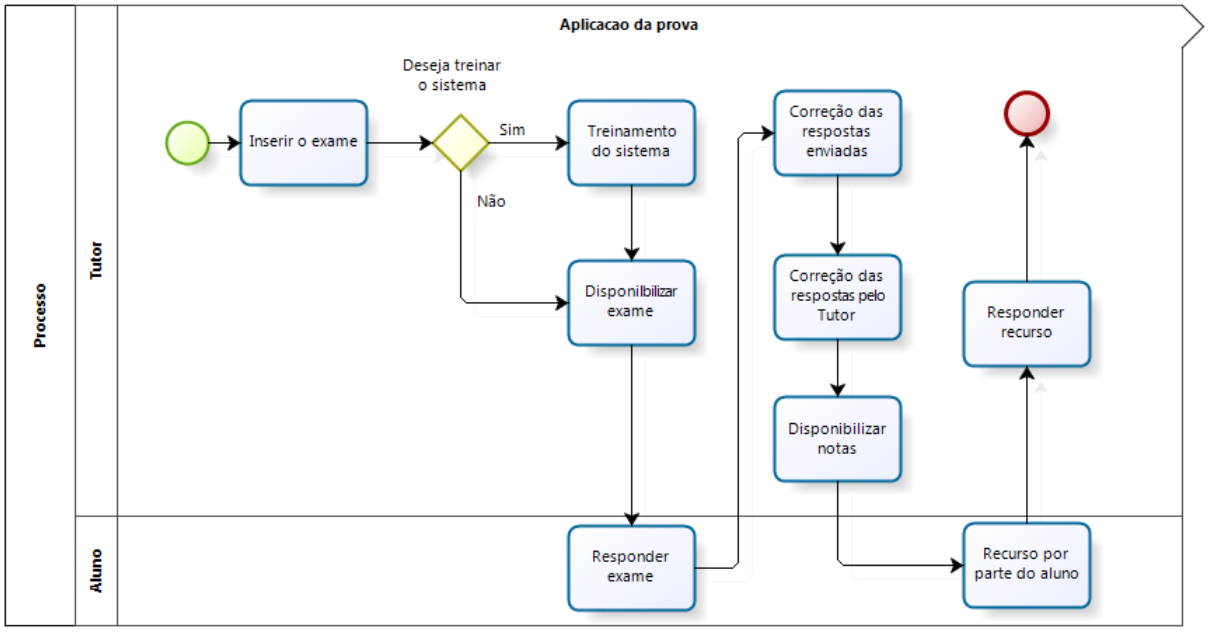

Figura 12 – Representa os passos no processo do Sistema de apoio de correção de respostas dissertativas

Inserir o exame: Para aplicar um exame é necessário cadastra-lo, uma vez cadastrado o exame é necessária à inserção das perguntas e gabaritos no sistema, para os textos de gabarito foi definida uma linguagem de marcação, que permitisse marcar partes mais importantes do texto gabarito, ela foi definida da seguinte maneira:

Foram divididas as perguntas em dois tipos, as “Quai”, que serão uma enumeração sem necessariamente uma ordem dos itens, e as “Como”, aonde a ordem dos itens enumerados será de importância à resposta.

A sintaxe:

Serão colocadas palavras, essas terão uma ordem, que pode ou não importar, dependendo do tipo da pergunta, essas palavras permitem agrupamentos por colchetes, [ ], que poderá ser alinhadas, e cada agrupamento permitirá operadores, são eles = (igual), ∼ (til), - (menos), > (maior que), < (menor que), que poderão ser combinados entre si, esses agrupamentos que definiram quais palavras serão importantes dentro da resposta.

Marcadores

defini prioridade de agrupamento nas palavras.

- - operador que define que o agrupamento pode diminuir a pontuação do gabarito.
- = operador que define que o agrupamento pode ser substituído por sinônimos.
- $\sim$ operador que define que o agrupamento pode ser substituído por um tesauro.
- $>$ operador que define que o agrupamento pode ser substituído a parte pelo todo.
- $<$ operador que define que o agrupamento pode ser substituído a todo pela parte (metonímia).

Os operadores $>$ (maior que),$<$ (menor que), além de definir sobre os agrupamentos, também aceitam um peso, logo após sua ocorrência, para saber quantos níveis deveram subir ou descer.

Exemplo: Como se faz miojo?

Tenha um [pacote]= de [miojo], tenha um [fogão]= , tenha [agua] e uma [panela]=, quebre o miojo dentro do pacote, coloque a [[panela]= com água] no [fogão]= , [coloque o [conteúdo]= do [pacote]= de [miojo na [panela]=]], [espera] de 5 a 10 [minutos]>< , está pronto.

Outro conceito que foi definido é o de "ideias", aonde seria extraído do texto gabarito as palavras que estão demarcadas com colchetes, e elas virariam ideias que o texto resposta posteriormente terá que ter.

Uma vez escolhido o tipo de pergunta, escrito a pergunta e definido um gabarito para a pergunta usando a sintaxe definida, essa pergunta seria salva.

Treinamento do sistema: Como já referente ao processo de aprendizado de maquina, a próxima parte é criar um grupos de respostas, aonde serão separadas em treino e testes, as de treino serão inseridas no sistema com a nota já preestabelecida e as ideias associadas, para que o sistema consiga aprender com elas, após esse passo será testado o aprendizado com o grupo de testes, aonde serão inseridos as respostas, e esperasse obter a nota pré-definida anteriormente, com isso o algoritmo genético estará treinado, para cada questão cadastrada poderá ser feito esse procedimento, o tutor pode disponibilizar um exame sem que todas as perguntas sejam treinadas anteriormente, ou nem uma pergunta seja treinada.

O tutor poderá cadastrar um exame, e posteriormente cadastrar as perguntas e gabaritos, assim como depois de cadastrar cada pergunta e gabarito, ele poderá cadastrar outra pergunta e gabarito, ou poderá treinar a que acabou de inserir, ele poderá inserir diversos perguntas e gabaritos e deixar para treinar posteriormente as perguntas e gabaritos, ele poderá cadastrar e treinar perguntas e gabaritos e deixar o exame salvo para ser disponibilizado para o recebimento das respostas.

Disponibilizar exame: O tutor disponibiliza um exame para os alunos enviarem respostas ao mesmo.

Responder exame: O aluno responde as questões do exame.

Correção das respostas enviadas: Uma vez disponibilizado o exame pelo tutor o sistema irá receber as respostas enviadas pelos alunos, e irá definir uma nota as respostas recebidas.

Correção das respostas pelo tutor: Uma vez fechado o exame, será mostrado ao tutor à nota, o texto resposta e as ideias associadas, as opções que ele terá no sistema serão o de aceitar a nota dada, que o sistema seguirá normalmente ou poderá recusar a nota, aonde o sistema irá perguntar qual nota seria mais adequada e pedir para que marque as ideias relacionadas naquela pergunta. Seguindo essa linha, poderá acontecer diversas circunstancias, sendo as principais delas:

- O sistema alterará a nota e aprenderá com o novo exemplo, sem alterar as notas anteriores ou posteriores, mas aplicará aquele novo exemplo em aplicações futuras.
- O sistema alterará a nota e aprenderá com o novo exemplo, alterará as notas anteriores ou posteriores, com isso o tutor terá que revalidar todas as notas que anteriormente estavam já conferidas.

Disponibilizar notas: Uma vez que o tutor tenha corrigido todas as notas, ele disponibilizará no sistema as notas, para visualização dos alunos.

Recurso por parte do aluno: Uma vez todas as notas corrigidas será a parte de recursos por parte do aluno, o aluno poderá reclamar sua nota abrindo um recurso.

Responder recurso: As opções que o tutor terá serão não aceitar o recurso e nada acontece, ou aceitar o recurso com isso alterando a nota dado o recurso, seguindo essa linha, poderá acontecer diversas circunstancias, sendo as mesmas da lista acima.

3.3 Análise do texto

A análise do texto, ou análise das respostas foi definido o processo da figura 13, dividido em: Quebrar o texto em frases, Marcar frases com ideias, Verificar melhor aderência e Calcular nota.

Quebrar o texto em frases: Para a análise do texto foi considerado a quebra do mesmo de acordo com as frases.

Marcar frases com ideais: Cada frase será analisada para verificar se ela contém alguma ideia inclusa, caso tenha, será analisada a aderência dessa frase com a frase do gabarito que contenha a mesma ideia.

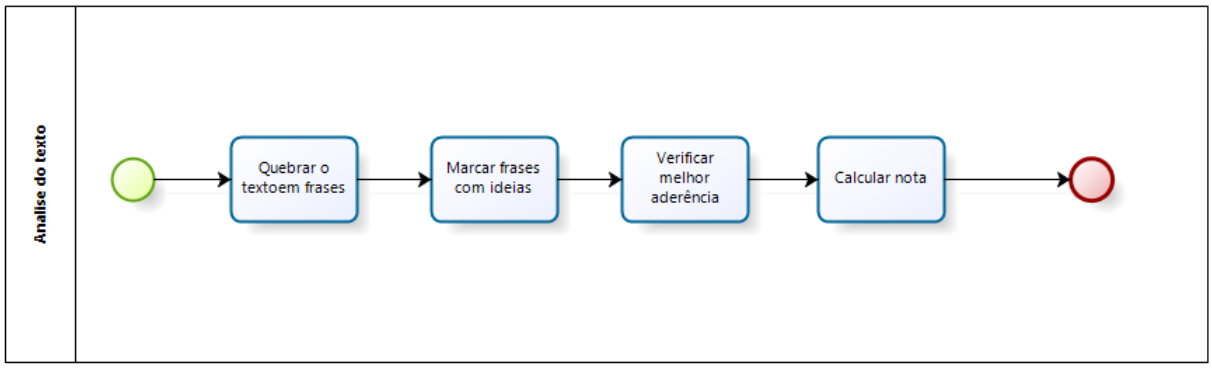

Figura 13 – Representa os passos no processo de análise de texto.

Verificar melhor aderência: O peso de aderência é o valor mínimo a ser alcançado pela similaridade entre as frases, a parti da divisão feita no cadastro das questões, uma vez que o *Latent Semantic Analysis* (LSA) será usado para as definidas como "Quais", e o STASIS para as definidas como “Como”, isso se deve ao fato que o STASIS leva em consideração á ordem das sentenças, mas será estudado qual deles é o melhor para ser usado em cada caso, o fator de aderência será analisado para que a nota seja calculada, uma vez que temos mapeado quais frases tem quais ideias, será testado com o algoritmo genético para cada frase da resposta qual a sua melhor similaridade com cada frase que contenha essa ideia no gabarito, se duas frases contenham a mesma ideia será passado a que tem maior similaridade com a frase gabarito correspondente, para ser aceito a similaridade terá que ser no mínimo o mesmo valor de aderência, para exemplo, se temos uma frase1 com a ideia1, da resposta, e uma frase2 com a ideia1 do gabarito, que foi considerado a melhor similaridade entre as ideias, e tenha similaridade de 80% e o fator de aderência seja de 90%, essa ideia não foi aceita.

Calcular nota: A nota será calculada de acordo com as ideias aceitas, e o peso que essas ideias tenham no sistema, assim sendo um somatório das ideais aceitas vezes o peso da ideia.

Caso o tutor, aceite a ideia correspondente na frase1 da resposta e na frase2 do gabarito, ele pode ou não alterar a nota, e esses dois fatores serão levados ao algoritmo genético para que seja recalculado tanto o fator de aderência quanto o peso que a ideia tem sobre a nota final.

Caso uma frase não seja mapeada a nem uma ideia ela será testada com as frases do gabarito que não encontraram nem uma frase que passaram do fator de aderência.

3.4 Algoritmo genético

O algoritmo genético que irá nivelar os pesos de cada ideia sobre o peso da nota, e o fator de aderência para cada ideia, inicialmente cada ideia terá seu peso igual na soma final de cada nota, assim sendo se tem quatro ideias, cada uma dessas terá influencia inicial em 25% da nota final, um fator de aderência mínimo terá que ser estudado para ser colocado, para o algoritmo genético tem as propostas de:

- Ajustar os pesos de acordo com a nota e as ideias contidas nele, sendo assim alterando os pesos caso uma ideia seja mais relevante ao tutor.
- Ajustar qual parte do texto se encaixa melhor para cada ideia.
- Ajustar os pesos de aderência.
- Ajustar as palavras de melhor aderência de acordo com a sintaxe de marcação.

O gene montado para o algoritmo genético será composto com elementos binários para mostrar que contem ou não a ideia, elementos decimais para o peso de cada ideia sobre a nota final, e elementos decimais para o fator de aderência, elementos decimais para a similaridade, e um elemento decimal para a nota final, a nota final será o objetivo da função do algoritmo genético, achar a melhor forma de moldar os elementos anteriores para que seja montada a nota final.

4 Desenvolvimento da Proposta

4.1 Descrição do projeto

O sistema de apoio à correção de respostas dissertativas é uma solução de software, para plataforma *web*, onde um tutor pode cadastrar exames de respostas dissertativas, e quando respondidas o sistema fará uma pré-avaliação da resposta, dando ao tutor uma nota que o guie na correção, sendo aberto para o aprendizado, com as técnicas de aprendizado de maquina, aonde o sistema irá melhora a pré-avaliação com a interação do tutor.

4.2 Proposta

O sistema desenvolvido para plataforma web, aonde um tutor consiga gerenciar seus exames de questões dissertativas, assim sendo, ele cadastrará um exame, cadastrará perguntas e gabaritos ao exame, disponibilizará para receber respostas, corrigirá exames, disponibilizar notas e corrigirá recursos, a parti do gabarito da resposta, que foi inserido usando a sintaxe de marcação, usará processamento de linguagem natural, algoritmos de similaridade e algoritmo genético, para determinar uma nota para a reposta, com a interação com o tutor, o sistema irá melhora a função da pré-avaliação, com isso se espera demandar menos tempo de correção pelo tutor.

Para o seu desenvolvimento será usado algumas práticas do Scrum, não serão adota todas pois algumas não se aplicas, como exemplo reuniões diárias, e a montagem do time Scrum, as práticas adotadas serão o uso de *sprints*, de duração de duas semanas, a organização das histórias em um *backlog* do produto e o *backlog* da *sprint*.

4.3 O sistema

Foram identificados no sistema os perfis, são eles o Tutor e Aluno, e o comum entre eles o usuário, de acordo com o perfil o sistema dará as seguintes ações:

- Tutor: Cadastrar exames, Cadastrar questões, Treinar o sistema, Avaliar as notas, Disponibilizar notas e Corrigir recursos.
- Aluno: Responder as questões, Visualizar correção, Entrar com recurso e Visualizar recurso.
- Usuário: Logar no sistema.

Foram derivadas Histórias de usuário para as ações, na tabela 5 podemos ver o *Backlog* do Produto Inicial:

Tabela 5 – *Backlog* do Produto

Número	História de usuário	Pontos
1	Eu como usuário quero logar no sistema para que meu perfil seja identificado.	5
2	Eu como Tutor quero cadastrar exames para poder cadastrar questões.	5
3	Eu como Tutor quero cadastrar questões e gabaritos para aplicar aos meus alunos.	18
4	Eu como Tutor quero inserir respostas há minha questão para treinar o sistema.	18
5	Eu como Aluno quero responder a questões para que eu possa ser avaliado.	2
6	Eu como Tutor quero poder mudar a nota dada pelo sistema para corrigir a divergência de nota dada.	8
7	Eu como Tutor quero poder disponibilizar as notas no sistema para meus alunos.	2
8	Eu como Aluno quero ver minha correção para que eu possa entender como minha resposta foi avaliada.	2
9	Eu como Aluno quero poder entrar com recurso para que minha nota seja reavaliada.	5
10	Eu como Tutor quero mudar uma nota mesmo depois de fechada para poder atender um recurso pedido por um aluno.	5
11	Eu como Aluno quero poder ver os recursos que eu cadastrei para ver o andamento dele.	2
	Total	72

Para todas as histórias de usuário foram derivadas tarefas a serem realizadas, abaixo temos as tabelas 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16.

Tabela 6 – Eu como usuário quero logar no sistema para que meu perfil seja identificado.

Tarefa	Dificuldade
Criar tabela no banco para usuários	2
Criar tabela no banco para perfis	2
Criar tela para login	2

Tabela 7 – Eu como Tutor quero cadastrar exames para poder cadastrar questões.

Tarefa	Dificuldade
Criar tabela no banco para exames	2
Criar tela para cadastrar exames	2

Tabela 8 – Eu como Tutor quero cadastrar questões e gabaritos para aplicar aos meus alunos.

Tarefa	Dificuldade
Criar tabela no banco para questões	2
Criar tabela no banco para ideias	2
Criar tabela no banco para frases	2
Criar algoritmo para extrair as frases do gabarito	5
Criar algoritmo para extrair as ideias das frases	5
Criar tela para cadastrar questões	2

Tabela 9 – Eu como Tutor quero inserir respostas há minha questão para treinar o sistema.

Tarefa	Dificuldade
Criar tabela no banco para respostas	2
Criar algoritmo para analisar existência de ideias das frases	5
Criar algoritmo para analisar melhor aderência	8
Criar algoritmo para calcular nota	2
Criar tela para cadastrar respostas	2

Tabela 10 – Eu como Aluno quero responder a questões para que eu possa ser avaliado.

Tarefa	Dificuldade
Criar tela para responder exames	2

Tabela 11 – Eu como Tutor quero poder mudar a nota dada pelo sistema para corrigir a divergência de nota dada.

Tarefa	Dificuldade
Criar algoritmo genético para balancear os pesos	8
Criar tela de correção de exames	2

Tabela 12 – Eu como Tutor quero poder disponibilizar as notas no sistema para meus alunos.

Tarefa	Dificuldade
Criar tela de disponibilizar notas	2

Tabela 13 – Eu como Aluno quero ver minha correção para que eu possa entender como minha resposta foi avaliada.

Tarefa	Dificuldade
Criar tela de visualizar correção	2

Tabela 14 – Eu como Aluno quero poder entrar com recurso para que minha nota seja reavaliada.

Tarefa	Dificuldade
Criar tabela no banco para recursos	2
Criar tela cadastrar recurso	2

Tabela 15 – Eu como Tutor quero mudar uma nota mesmo depois de fechada para poder atender um recurso pedido por um aluno.

Tarefa	Dificuldade
Criar tela visualizar todos os recursos	2
Criar tela responder recurso	2

Tabela 16 – Eu como Aluno quero poder ver os recursos que eu cadastrei para ver o andamento dele.

Tarefa	Dificuldade
Criar tela visualizar recurso	2

4.4 Definição das tecnologias

Para o processamento de linguagem natural, citado por (ZHU; LAN, 2013) e (CROFT et al., 2013), temos a biblioteca *Natural Language Toolkit*(NLTK)(BIRD; KLEIN; LOPER, 2009), desenvolvida em Python, ela suporta diversas funcionalidades necessárias ao processamento de linguagem natural, sendo de licenciada pela Apache License Version 2.0, tendo seu uso livre para desenvolvimento e comercialização.

Para o desenvolvimento do sistema web, será usado o padrão de desenvolvimento MVC, e o paradigma de programação Orientação a Objetos. Com a necessidade de se usar a biblioteca do *Natural Language Toolkit*(NLTK)(BIRD; KLEIN; LOPER, 2009), o desenvolvimento web será feito em linguagem Python, com o *framework* Django(DJANGO. . . , 2013), que nos permite o desenvolvimento web com Python.

Para o banco de dados será usado o Mysql.

Para o controle de versão de código será usado o git.

Para a análise de qualidade do código será usado o programa Radon, uma ferramenta de análise estática de código Python, como já analisado por (TADA; FELIX; FRINHANI, 2015) é a ferramenta que mais se aproxima dos reais valores das métricas de código para Python.

4.5 Cronograma de desenvolvimento

Para o TCC 1 foi montado o cronograma 17, nele estão às atividades realizadas.

A proposta de execução para o TCC2 está descrita no cronograma 18, temos a execução do desenvolvimento, Aplicação do sistema em um estudo de caso, a análise dos dados e escrita da conclusão.

Execução do desenvolvimento: Usando o formato de *sprint*, aonde cada *sprint* terá duas semanas, temos na tabela de execução das *sprint* 19, as datas de início e fim da *sprint*, histórias as serem desenvolvidas e a pontuação total da *sprint*:

Tabela 17 – Cronograma de trabalho para o TCC1

Atividade	8/2015	9/2015	10/2015	11/2015
Criar 10 perguntas base	X			
Criar proposta de TCC1	X			
Pesquisa sobre artigos de *semantic text similarity*	X			
Definir linguagem formal		X		
Estudo dos algoritmos de similaridade		X		
Estudo dos algoritmos de *machine learning*		X		
Pesquisa de implementações de algoritmos genéticos			X	
Teste dos algoritmos (similaridade e genéticos)			X	
Organização das referências			X	
Escrita do TCC 1 Capítulo 3-Proposta				X
Escrita do TCC 1 Capítulo 2-Referencial teórico				X
Escrita do TCC 1 Capítulo 4-Engenharia de Software				X
Escrita do TCC 1 Capítulo 1-Introdução				X

Tabela 18 – Cronograma de trabalho para o TCC2

Etapa	2/2016	3/2016	4/2016	5/2016	6/2016
Desenvolvimento do sistema	X	X			
Aplicação do sistema em um estudo de caso			X	X	
Análise dos dados			X	X	
Escrita do TCC2				X	X

Tabela 19 – Disposição das histórias nas *sprints*

Sprint	Início	Término	Histórias	Total de pontos
1	8 de fevereiro de 2016	19 de fevereiro de 2016	1,2,3	28
2	22 de fevereiro de 2016	4 de março de 2016	4,5,6	28
3	7 de março de 2016	18 de março de 2016	7,8,9	9
4	21 de março de 2016	1 de abril de 2016	10,11	7

Aplicação do sistema em um estudo de caso: Uma vez terminada a implementação do sistema, ele será aplicado a um estudo de caso na disciplina de Fundamentos de Arquitetura de Computadores.

análise dos dados: O sistema será avaliado pelos critérios listados abaixo, referentes a qualidade do algoritmo, acurácia do sistema e ganhos do processo.

- Acuraria da nota da avaliação do sistema.
- Aperfeiçoamento do sistema para cada exame.
- Tempo de execução do sistema.

Escrita do TCC2: A escrita do TCC 2 inclui a sumarização dos dados de execução das *sprints*, os dados da aplicação do sistema em um estudo de caso e a análise dos dados,

considerações finais e trabalhos futuros.

5 Considerações finais

Através do que ja foi realizado percebesse que há um campo de utilização muito grande, o sistema tem uma complexidade que aparenta ser simples, por ser uma caixa de texto e uma tela de mostrar notas, que por traz se tem o processamento de linguagem natural e um processo de aprendizado de maquina apoiado por algoritmo genético, para que seja aperfeiçoado as avaliações.

Já foram estudados em algoritmos de similaridade semântica e algoritmos genéticos, com isso foi criado uma proposta de sistema que consiga avaliar questões dissertativas e aprender com a interação do tutor, com isso em um futuro próximo espera que a avaliação seja totalmente automatizada.

Normalmente levasse muito tempo corrigindo exames com questões dissertativas, os benefícios esperados do sistema de apoia abrangem a diminuição do tempo gasto com a correção, implicando em divulgação das notas em um menor tempo, com isso o aluno que tirou uma nota considerada ruim, terá um maior tempo para uma reação, com mais tempo para se esforçar.

Referências

ABRAEAD. *Anuario Brasileiro Estatistico de Educação Aberta e a Distância*. 2008. Citado 2 vezes nas páginas 15 e 25.

BIRD, S.; KLEIN, E.; LOPER, E. *Natural language processing with Python*. 1st ed. ed. Beijing ; Cambridge [Mass.]: O'Reilly, 2009. ISBN 978-0-596-51649-9. Citado na página 62.

BOOCH, G. Object-oriented development. *IEEE Transactions on Software Engineering*, SE-12, n. 2, p. 211–221, fev. 1986. ISSN 0098-5589. Citado 2 vezes nas páginas 51 e 52.

CARRIJO, I. B. *Extração de regras operacionais ótimas de sistemas de distrubuição de água através de algoritmos genéticos multiobjetivo e aprendizado de máquina*. Tese (Doutorado) — Universidade de São Paulo, Escola de Engenharia de São Carlos, 2004. Disponível em: <http://bases.bireme.br/cgi-bin/wxislind.exe/iah/online/?IsisScript=iah/iah.xis&src=google&base=LILACS&lang=p&nextAction=lnk&exprSearch=415521&indexSearch=ID>. Citado 9 vezes nas páginas 15, 35, 36, 41, 42, 43, 45, 46 e 47.

CROFT, D. et al. A fast and efficient semantic short text similarity metric. In: *2013 13th UK Workshop on Computational Intelligence (UKCI)*. [S.l.: s.n.], 2013. p. 221–227. Citado na página 62.

DAVIS, L. (Ed.). *Handbook of genetic algorithms*. New York: Van Nostrand Reinhold, 1991. ISBN 978-0-442-00173-5. Citado 2 vezes nas páginas 42 e 46.

DEERWESTER, S. et al. Indexing by latent semantic analysis. *JOURNAL OF THE AMERICAN SOCIETY FOR INFORMATION SCIENCE*, v. 41, n. 6, p. 391–407, 1990. Citado na página 31.

DJANGO (Versão 1.5). 2013. Disponível em: <https://djangoproject.com>. Citado na página 62.

FILHO, A. R. P. *A Atividade Questionário em Moodle*. 2009. Disponível em: <http://giselebrugger.com/tutorial/questionarios_moodle_1_9_3.pdf>. Citado na página 25.

GALVAO, C. d. O. *Sistemas inteligentes aplicacoes a recursos hidricos e ciencias ambientais*. Porto Alegre: UFRGS: ABRH, 1999. ISBN 978-85-7025-527-3. Citado na página 41.

GIL, A. C. *Como elaborar projetos de pesquisa*. São Paulo: Atlas, 2008. ISBN 978-85-224-3169-4. Citado na página 27.

GOLDBERG, D. E. *Genetic Algorithms in Search, Optimization and Machine Learning*. 1st. ed. Boston, MA, USA: Addison-Wesley Longman Publishing Co., Inc., 1989. ISBN 978-0-201-15767-3. Citado na página 41.

JUNIOR, J. R. C. *DESENVOLVIMENTO DE UMA METODOLOGIA PARA MINERAÇÃO DE TEXTOS*. Tese (TEXTO) — PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO DE JANEIRO - PUC-RIO, maio 2008. Citado 3 vezes nas páginas 29, 30 e 31.

KRASNER, G. E.; POPE, S. T. A Cookbook for Using the Model-view Controller User Interface Paradigm in Smalltalk-80. *J. Object Oriented Program.*, v. 1, n. 3, p. 26–49, ago. 1988. ISSN 0896-8438. Disponível em: <http://dl.acm.org/citation.cfm?id=50757.50759>. Citado 3 vezes nas páginas 15, 51 e 52.

LANDAUER, T. K.; FOLTZ, P. W.; LAHAM, D. An introduction to latent semantic analysis. *Discourse Processes*, v. 25, n. 2-3, p. 259–284, jan. 1998. ISSN 0163-853X, 1532-6950. Disponível em: <http://www.tandfonline.com/doi/abs/10.1080/01638539809545028>. Citado 4 vezes nas páginas 15, 31, 32 e 33.

LI, Y.; BANDAR, Z.; MCLEAN, D. An approach for measuring semantic similarity between words using multiple information sources. *IEEE Transactions on Knowledge and Data Engineering*, v. 15, n. 4, p. 871–882, jul. 2003. ISSN 1041-4347. Citado na página 34.

LI, Y. et al. Sentence similarity based on semantic nets and corpus statistics. *IEEE Transactions on Knowledge and Data Engineering*, v. 18, n. 8, p. 1138–1150, ago. 2006. ISSN 1041-4347. Citado na página 34.

MICHALEWICZ, Z.; ATTIA, N. Evolutionary Optimization of Constrained Problems. p. 98–108, 1994. Citado na página 41.

MICHALSKI, R. S.; BRATKO, I.; KUBAT, M. (Ed.). *Machine learning and data mining: methods and applications*. Reprint. Chichester: Wiley, 1998. ISBN 978-0-471-97199-3. Citado na página 35.

MITCHELL, T. M. *Machine learning*. International ed., [reprint.]. New York, NY: McGraw-Hill, 1997. (McGraw-Hill series in computer science). ISBN 978-0-07-115467-3. Citado na página 37.

PEREIRA, A. T. C.; SCHMITT, V.; DIAS, M. R. A. C. *Ambientes Virtuais de Aprendizagem: em diferentes contextos*. 2007. Rio de Janeiro: Ciência Moderna Ltda. Citado na página 25.

REZENDE, S. O. (Ed.). *Sistemas inteligentes: fundamentos e aplicações*. 1. ed. ed. Barueri, SP: Ed. Manole, 2003. ISBN 978-85-204-1683-9. Citado 5 vezes nas páginas 15, 34, 35, 36 e 40.

RUSSELL, S.; NORVIG, P. *INTELIGÊNCIA ARTIFICIAL, 3E*. [S.l.: s.n.], 2013. ISBN 978-85-352-3701-6. Citado na página 29.

SCHWABER, K.; SUTHERLAND, J. *Guia do Scrum Um guia definitivo para o Scrum: As regras do jogo*. 2013. Disponível em: <http://www.scrumguides.org/docs/scrumguide/v1/Scrum-Guide-Portuguese-BR.pdf>. Citado 3 vezes nas páginas 49, 50 e 51.

SILVA, A. J. M. *IMPLEMENTAÇÃO DE UM ALGORITMO GENÉTICO UTILIZANDO O MODELO DE ILHAS*. Tese (Doutorado), 2005. Citado 8 vezes nas páginas 15, 17, 42, 43, 44, 45, 46 e 47.

TADA, P. H.; FELIX, M. L.; FRINHANI, C. L. *Comparativo entre Ferramentas de Análise Estática de Código Python*. 2015. Citado na página 62.

ZHU, T.-T.; LAN, M. Measuring short Text Semantic Similarity using multiple measurements. In: *2013 International Conference on Machine Learning and Cybernetics (ICMLC)*. [S.l.: s.n.], 2013. v. 02, p. 808–813. Citado na página 62.