

## SPELLING-GRAMMATICAL ESSAY CORRECTION USING ARTIFICIAL INTELLIGENCE

Pedro Henrique Gonçalves Bonel - FATEC SOROCABA - Orcid: <https://orcid.org/0000-0002-6954-8264>

Maria Das Graças Junqueira Machado Tomazela - FACULDADE DE TECNOLOGIA DE SOROCABA - Orcid: <https://orcid.org/0000-0002-5471-2658>

Created in 1998, the ENEM (National High School Examination) is a test carried out to enable access to higher education in public universities in Brazil through the Unified Selection System (SiSU). The test consists of two stages, a questionnaire with 180 questions about the main subjects covered during the three years of high school and the development of an essay, most of the time essay-argumentative. Part of the correction process, more specifically the questionnaire, is carried out in an automated way, but the essays are manually corrected by a board of certified teachers for this action. Analyzing the sites that present the numbers of applicants for ENEM, it is possible to notice a sharp growth in the number of subscribers, which implies hiring an increasing number of professors to carry out the correction of these essays. In order to simplify the process of proofreading and evaluating essays, the objective of this work was to implement a tool that uses Artificial Intelligence (AI) to automatically correct essay-argumentative essays using Natural Language Processing concepts to assess the spelling and grammar of these texts. and reduce the manual workload of the review boards. To carry out this work, the methodology of experimental research was used, the main tools used in this process were the Python programming language and the LanguageTool library, an open-source tool that uses the AI paradigm, natural language processing, to correct the grammar and spelling of texts. Some essays were analyzed to assess the machine's ability to correct texts, comparing them with corrections made by professionals. Some essays were very similar in corrections, but when the grades approached the extremes, the machine had difficulty in correctly evaluating the text.

Keywords: Artificial Intelligence, ENEM, Education, Natural Language Processing, Technology

## CORREÇÃO ORTOGRÁFICA-GRAMATICAL DE REDAÇÕES UTILIZANDO INTELIGÊNCIA ARTIFICIAL

Criado em 1998, o ENEM (Exame Nacional do Ensino Médio) é uma prova realizada para possibilitar o acesso ao ensino superior nas universidades públicas do Brasil por meio do Sistema de Seleção Unificado (SiSU). A prova é composta por duas etapas, um questionário de 180 questões sobre as principais matérias abordadas durante os três anos do Ensino Médio e o desenvolvimento de uma redação, na maioria das vezes dissertativa-argumentativa. Parte do processo de correção, mais especificamente o questionário, é realizado de forma automatizada, porém as redações são corrigidas manualmente por uma banca de professores certificados para essa ação. Analisando-se os sites que apresentam os números de inscritos para o ENEM, é possível notar um acentuado crescimento na quantidade de inscritos que implica na contratação de um número cada vez maior de professores para executar a correção dessas redações. Visando a simplificar o processo de correção e avaliação de redações o objetivo deste trabalho foi implementar uma ferramenta que utiliza Inteligência Artificial (IA) para corrigir automaticamente as redações dissertativas-argumentativas utilizando conceitos de Processamento de Linguagem Natural para avaliar a ortografia e a gramática desses textos e reduzir a carga manual das bancas avaliadoras. Para a realização desse trabalho foi utilizada a metodologia da pesquisa experimental, as principais ferramentas usadas nesse processo foram a linguagem de programação Python e a biblioteca LanguageTool, uma ferramenta open-source que utiliza o paradigma de IA, processamento de linguagem natural, para corrigir a gramática e a ortografia de textos. Foram analisadas algumas redações para avaliar a capacidade da máquina em corrigir textos, comparando-as com as correções feitas pelos profissionais. Algumas redações se assemelharam bastante nas correções, mas quando as notas se aproximavam dos extremos, a máquina sentia dificuldade em avaliar corretamente o texto.

Palavras-chave: Inteligência Artificial, ENEM, Educação, Processamento de Linguagem Natural, Tecnologia

## CORREÇÃO ORTOGRÁFICA-GRAMATICAL DE REDAÇÕES UTILIZANDO INTELIGÊNCIA ARTIFICIAL

### SPELLING-GRAMMATICAL ESSAY CORRECTION USING ARTIFICIAL INTELLIGENCE

*Pedro Henrique Gonçalves Bonel*  
<https://orcid.org/0000-0002-6954-8264>

451.002.998-51

*Centro Paula Souza – Fatec Sorocaba/SP*  
[pedro.bonel@gmail.com](mailto:pedro.bonel@gmail.com)

*Orientador: Profa Dra. Maria das Graças J. M. Tomazela*  
<https://orcid.org/0000-0002-5471-2658>

085.107.058-28

*Centro Paula Souza – Fatec Indaiatuba/SP*  
[gtomazela@fatecindaiatuba.edu.br](mailto:gtomazela@fatecindaiatuba.edu.br)  
[graca.tomazela@fatec.sp.gov.br](mailto:graca.tomazela@fatec.sp.gov.br)

**RESUMO:** Criado em 1998, o ENEM (Exame Nacional do Ensino Médio) é uma prova realizada para possibilitar o acesso ao ensino superior nas universidades públicas do Brasil por meio do Sistema de Seleção Unificado (SiSU). A prova é composta por duas etapas, um questionário de 180 questões sobre as principais matérias abordadas durante os três anos do Ensino Médio e o desenvolvimento de uma redação, na maioria das vezes dissertativa-argumentativa. Parte do processo de correção, mais especificamente o questionário, é realizado de forma automatizada, porém as redações são corrigidas manualmente por uma banca de professores certificados para essa ação. Analisando-se os sites que apresentam os números de inscritos para o ENEM, é possível notar um acentuado crescimento na quantidade de inscritos que implica na contratação de um número cada vez maior de professores para executar a correção dessas redações. Visando a simplificar o processo de correção e avaliação de redações o objetivo deste trabalho foi implementar uma ferramenta que utiliza Inteligência Artificial (IA) para corrigir automaticamente as redações dissertativas-argumentativas utilizando conceitos de Processamento de Linguagem Natural para avaliar a ortografia e a gramática desses textos e reduzir a carga manual das bancas avaliadoras. Para a realização desse trabalho foi utilizada a metodologia da pesquisa experimental, as principais ferramentas usadas nesse processo foram a linguagem de programação Python e a biblioteca LanguageTool, uma ferramenta *open-source* que utiliza o paradigma de IA, processamento de linguagem natural, para corrigir a gramática e a ortografia de textos. Foram analisadas algumas redações para avaliar a capacidade da máquina em corrigir textos, comparando-as com as correções feitas pelos profissionais. Algumas redações se assemelharam bastante nas correções, mas quando as notas se aproximavam dos extremos, a máquina sentia dificuldade em avaliar corretamente o texto.

**ABSTRACT:** Created in 1998, the ENEM (National High School Examination) is a test carried out to enable access to higher education in public universities in Brazil through the

Unified Selection System (SiSU). The test consists of two stages, a questionnaire with 180 questions about the main subjects covered during the three years of high school and the development of an essay, most of the time essay-argumentative. Part of the correction process, more specifically the questionnaire, is carried out in an automated way, but the essays are manually corrected by a board of certified teachers for this action. Analyzing the sites that present the numbers of applicants for ENEM, it is possible to notice a sharp growth in the number of subscribers, which implies hiring an increasing number of professors to carry out the correction of these essays. In order to simplify the process of proofreading and evaluating essays, the objective of this work was to implement a tool that uses Artificial Intelligence (AI) to automatically correct essay-argumentative essays using Natural Language Processing concepts to assess the spelling and grammar of these texts. and reduce the manual workload of the review boards. To carry out this work, the methodology of experimental research was used, the main tools used in this process were the Python programming language and the LanguageTool library, an open-source tool that uses the AI paradigm, natural language processing, to correct the grammar and spelling of texts. Some essays were analyzed to assess the machine's ability to correct texts, comparing them with corrections made by professionals. Some essays were very similar in corrections, but when the grades approached the extremes, the machine had difficulty in correctly evaluating the text.

**PALAVRAS-CHAVE:** Inteligência Artificial. ENEM. Educação. Processamento de Linguagem Natural. Tecnologia.

**KEYWORD:** Artificial Intelligence. ENEM. Education. Natural Language Processing. Technology.

## 1 INTRODUÇÃO

Em 1998, o Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira (INEP) criou o Exame Nacional do Ensino Médio (ENEM) para avaliar o desempenho dos alunos do Ensino Médio e a qualidade do ensino naquele ano. A prova é atualmente composta por 180 questões dissertativas dos temas abordados durante o ensino médio e o desenvolvimento de uma redação dissertativa-argumentativa.

A partir de sua segunda edição em 1999, o ENEM passou a ser utilizado como ferramenta de ingresso às faculdades públicas do Brasil.

De 2004 em diante, a prova passou a ser uma ferramenta de avaliação do aluno para sua aplicação no Programa Universidade para Todos (ProUni) e no Financiamento Estudantil (Fies).

Atualmente, o processo de correção de redação do ENEM é manual, um mesmo texto é avaliado e pontuado por uma banca de professores especializados em correções de textos. Essas bancas avaliadoras estão espalhadas por todas as regiões do Brasil, mas

com essa quantidade de inscritos é natural que haja um grande volume de redações para serem corrigidas por uma única banca, gerando desgaste, fadiga, queda de desempenho e a demanda de um longo período para correção de todos os textos.

Com a utilização de técnicas de Processamento de Linguagem Natural (PLN) o processo de correção das redações torna-se muito mais fácil e rápido devido ao alto desempenho das máquinas no processamento de dados escritos.

A partir desse contexto a questão norteadora desta pesquisa foi: “Como as técnicas de IA podem auxiliar na correção automática da ortografia e da gramática de um texto argumentativo-dissertativo para auxiliar os corretores humanos?”

Desta forma, o objetivo deste trabalho foi implementar uma ferramenta que utiliza Inteligência Artificial (IA) para corrigir automaticamente as redações dissertativas-argumentativas utilizando conceitos de Processamento de Linguagem Natural para avaliar a ortografia e a gramática de um texto argumentativo-dissertativo.

## 2 METODOLOGIA

Para atingir os objetivos desta pesquisa, optou-se pela abordagem experimental, que consiste em determinar um objeto de estudo, selecionar as variáveis que seriam capazes de influenciá-lo, definir as formas de controle e de observação dos efeitos que a variável produz no objeto (GIL, 2007). A principal ferramenta utilizada para nesse processo foi a linguagem de programação Python, devido às diversas bibliotecas voltadas para esse segmento que linguagem possui.

Para a realização do experimento, foram utilizadas redações retiradas do Banco de Redações UOL, uma base de dados na qual vestibulandos enviam redações de temas diversos para serem avaliadas por profissionais responsáveis pelas correções oficiais do ENEM. As redações foram retiradas em seu estado inicial, sem qualquer correção ou ajuste feita pelos profissionais, foram escolhidas redações com notas diversas, para analisar como o corretor reagiria aos erros apresentados. A busca foi realizada utilizando a linguagem de programação Python para acessar o site, buscar a redação a partir da nota e copiá-la para um arquivo texto no formato texto (.txt).

Após as redações serem obtidas, utilizou-se do Python novamente, dessa vez para abrir os arquivos .txt individualmente e processá-los utilizando a biblioteca LanguageTool, uma ferramenta *open-source* que utiliza o paradigma de IA, processamento de linguagem natural, para corrigir a gramática e a ortografia de um determinado texto,

adaptando-se ao contexto e sugerindo alterações pertinentes. As sugestões de correções foram inseridas no mesmo arquivo .txt aberto anteriormente.

Em seguida, foram comparadas as redações corrigidas pela máquina e pelos profissionais para verificar as diferenças e semelhanças de um corretor humano e um corretor automático, e assim avaliar o sucesso do corretor automático.

## 2 DESENVOLVIMENTO

A fundamentação desse trabalho baseou-se nos conceitos de Inteligência artificial e Processamento de Linguagem Natural. Inteligência Artificial (IA) foi definida de forma ampla por Rich e Knight (1991) como: “Uma área de pesquisa que investiga formas de habilitar o computador a realizar tarefas nas quais, até o momento, o ser humano tem um melhor desempenho”.

Russel e Norvig (1995) dividiram o estudo da IA em quatro abordagens, como em um plano cartesiano, no qual o topo representa o processo de pensamento e raciocínio, a base representa o comportamento, a esquerda mede o sucesso nos termos do desempenho humano e a direita retrata o conceito ideal de inteligência, chamado pelos autores de racionalidade.

Com o passar das décadas, diversas aplicações diferentes para a IA foram sendo criadas, como o Machine Learning para ser aplicada na Análise de Dados e Business Intelligence (BI), Sistemas Especialistas para a resolução de problemas de forma automatizada ou até mesmo IAs capazes de entender e interpretar linguagens faladas pelos humanos, aplicação conhecida como Processamento de Linguagem Natural, apresentada nas seções seguintes por ser o foco da presente pesquisa

Para Vajjala et al. (2017) o PLN pode ser definido por uma área na ciência da computação que trata métodos para analisar, modelar e entender a linguagem falada pelos seres humanos. Os autores dividiram a área em dez tarefas: modelagem da linguagem, classificação textual, extração da informação, recuperação da informação, agente conversacional, sumarização de texto, resolução de perguntas, tradução de máquina e modelagem de tópicos.

Bird (2009) define o Processamento de Linguagem Natural (PLN) como a habilidade da máquina em processar e interpretar a linguagem conforme falada pelos humanos, também conhecida como linguagem natural. Na prática, o processo demanda etapas mais complexas, como a definição de gramática ou a geração de frases.



Para Lago (2016), uma gramática é uma especificação formal da estrutura das sentenças permitidas em uma linguagem. A gramática pode ser definida especificando símbolos terminais, não-terminais e regras de produção. Os símbolos terminais são as palavras da linguagem, os não terminais são os componentes das sentenças e as regras de produção expandem os símbolos não-terminais em símbolos terminais e não-terminais.

Durante a execução de um algoritmo de PLN, são executados os passos de Análise pragmática, Análise semântica, Análise sintática, Análise léxica e Tokenização.

Para Barbosa (2017), a tokenização é a etapa mais básica do PLN, na qual a frase é dividida em palavras para que os próximos passos possam ser executados.

A análise léxica trata-se de um dos passos primordiais para o processamento de texto escrito em linguagem natural. De acordo com Barbosa (2017), uma palavra pode ser vista de duas maneiras, como uma sequência de caracteres no texto a ser analisado, como um verbo ou substantivo, ou então como um objeto abstrato que serve de base para uma série de palavras variantes. A maioria dos estudos na área de PLN determina que a forma mais básica de análise de significado é por meio da frase. Dessa forma, a análise sintática preocupa-se em analisar cuidadosamente e individualmente cada frase para determinar sua estrutura e significado, definindo gramáticas e árvores sintáticas para o processo. A análise semântica é a parte do PLN responsável por interpretar o texto em sua totalidade, analisando as palavras, suas conexões, gramáticas, técnicas linguísticas e utilizando conhecimentos anteriores obtidos pelo corpus de treinamento. A análise semântica se mostra uma das tarefas mais complexas devido aos diversos significados que as palavras e termos podem ter, como o termo “passou a mão” que pode significar literalmente passar a mão em algo, ou então o ato de furtar um objeto. Para evitar interpretações erradas, é necessário o treinamento com diversos textos para que a máquina aprenda a identificar o contexto em que cada termo se encaixa. A última fase do processo de PLN, chamada de análise pragmática busca suprir as falhas da fase anterior, utilizando pronomes como “o” e “seu” e analisando frases próximas da frase processada para encontrar a coerência textual e análise do discurso.

A importância dessa área de pesquisa pode ser vista em diversas pesquisas relacionadas a essa, destaca-se aqui o trabalho de Santos (2017) que utilizou o Processamento de Linguagem Natural (PLN) em conjunto com algoritmos genéticos para realizar a avaliação e correção de redações do ENEM e o trabalho de Picoli (2016) que utilizou o Processamento de Linguagem Natural (PLN) para comparar três métodos de coleta de palavras e expressões: O primeiro foi a coleta manual por introspecção ou auxílio

da web, o outro foi por meio da extração a partir de um dicionário PLN existente e o último ocorreu pela Unitex, ferramenta PLN bastante utilizada.

A partir desse contexto, essa pesquisa se propôs analisar algumas redações de notas diversas para avaliar a capacidade de um corretor automático, visando a subsidiar a correção automática de redações do ENEM.

#### 4 RESULTADOS OBTIDOS

Usando como base as redações do banco de redações da UOL, notaram-se semelhanças e diferenças da ferramenta de correção e do corretor humano. Nas redações corrigidas por profissionais, as palavras em negrito representam erros ortográficos, as palavras em verde eram as correções das palavras em negrito e as frases em vermelho foram avaliadas como inconsistentes. Todas as redações corrigidas pela máquina estavam em seu estado original, mantendo as inconsistências e sem nenhuma correção, para que o grau de sucesso da correção automática fosse avaliado.

Com a redação corrigida pelo humano, observam-se correções de erros ortográficos visíveis, mas também erros gramaticais precisamente pontuados, para que se adaptem aos padrões de uma boa redação do ENEM, como por exemplo em substituições de frases como “irá suscitar uma potencialização na desigualdade social” para apenas “aumentar a desigualdade”, renunciando a um vocabulário rebuscado para tornar o texto mais enxuto e de leitura menos cansativa. Além disso, o profissional faz algumas sugestões para retirada de trechos inconsistentes para a redação. Um possível deslize cometido pelo corretor humano foi com a palavra “transumanismo” que não foi encontrada ao consultar o dicionário Michaelis online.

O texto corrigido automaticamente mostrou-se incapaz de apresentar a mesma sensibilidade com a gramática que o corretor humano, mas ainda fez sugestões para correção de palavras estrangeiras como “chip”, uso de vírgula e a correção da palavra “transumanismo”. Por fim, a máquina fez uma sugestão desconexa ao sugerir a substituição do termo “tipos de” por “APAGAR”, possivelmente por algum erro de aprendizado, porém sua outra sugestão para o mesmo termo estava dentro dos padrões aceitáveis.

Uma redação nota 1000 mostrou-se impecável na avaliação do profissional. Porém a máquina ainda sugeriu correções independentemente de sua configuração de linguagem. Algumas dessas sugestões não faziam sentido, como a de substituição das aspas, ou a de substituição de “passo” por “paço” num contexto em que “passo” era mais apropriado.

Porém uma sugestão interessante foi a substituição de “claramente” por outro termo sob o argumento de que o termo é ambíguo e evasivo.

Uma redação nota 0 avaliada por um profissional apresentava-se com diversos deslizes em todas os campos de avaliação de uma redação do ENEM. Apesar de serem necessários mais que erros ortográficos e gramaticais para uma redação zerar, porém mesmo com a grande quantidade de deslizes a máquina sugeriu apenas uma correção ortográfica, que não é pertinente para uma correção real, já que o termo “internet”, apesar de estrangeirismo, não é considerado um erro ortográfico na avaliação do ENEM.

A tabela 1 apresenta o número de deslizes apontados em cada redação de acordo com o método de correção

*Tabela 1-Comparação entre correções*

Redações	Correção manual	Correção automática configurada em pt-BR
Redação nota média	13	9
Redação nota máxima	0	4
Redação nota zero	14	1

*Fonte: O autor*

A máquina se assemelha bastante ao corretor humano ao corrigir uma redação de nota média, mas peca bastante ao analisar uma redação nota 0, principalmente pelo motivo de uma redação nota 0 apresentar diversos erros além dos ortográficos.

## 5 CONSIDERAÇÕES FINAIS

Após a análise dos textos conclui-se que essa proposta mostrou-se bastante útil para auxiliar os corretores profissionais durante o processo de correção de redações, pois apesar de não possuir a mesma sensibilidade que um humano nesse processo, ainda foi capaz de fazer sugestões bastante pontuais, como a correção de estrangeirismos e substituição de termos para que se adaptassem melhor a uma redação oficial, pontos importantes para uma avaliação de nível nacional como o ENEM, as vezes encontrando deslizes que até mesmo os humanos deixaram passar.

A pesquisa ainda está em seus passos iniciais, necessitando alguns ajustes e treinamento da máquina para detectar mais deslizes e tentar simular a mesma sensibilidade de correção de um profissional. Contudo, espera-se que após os devidos ajustes essa



ferramenta seja amplamente utilizada no processo de correção de redações em cada edição do ENEM, tornando o processo mais eficiente e menos cansativo.

## REFERÊNCIAS

BARBOSA, Jardeson. **Introdução Ao Processamento De Linguagem Natural Usando Python**, 2017, Piauí. Livro Anais - Artigos e Minicursos. Piauí: III Escola Regional de Informática do Piauí, 2017.

BIRD, Steve. **Natural Language Processing With Python**. Sebastopol: O'Reilly Media, 2009.

LAGO, Silvio do. **Processamento De Linguagem Natural**. São Paulo, 2016.

PICOLI, Larissa et al. **Uso De Uma Ferramenta De Processamento De Linguagem Natural Como Auxílio À Coleta De Exemplos Para O Estudo De Propriedades Sintático-Semânticas De Verbos**. Hal, [s. l], v. 1, n. 1, p. 1-12, jan. 2016.

RICH, Elaine; KNIGHT, Kevin. **Artificial intelligence**. New York: McGraw-Hill, 1991. 621 p.

RUSSELL Stuart; NORVIG, Peter. **Artificial Intelligence: A Modern Approach**. New Jersey: Pearson Prentice Hall, 1995.

SANTOS, Jário. **Avaliação Léxico-Sintática De Atividades Escritas Em Algoritmo Genético E Processamento De Linguagem Natural: Um Experimento No Enem**. 2016. 16 f. Dissertação (Mestrado) - Curso de Ciência da Computação, Universidade Federal de Alagoas, Alagoas, 2016. Cap. 16.

VAJJALA, Sowmya et al. **Practical Natural Language Processing: a comprehensive guide to building real-world nlp systems**. Sebastopol: O'Reilly, 2017