

A Analítica da Escrita para Identificação de Indicadores de Qualidade Textual

Ricardo Radaelli Meira, PPGIE/UFRGS, ricardoradaelli@gmail.com, 0000-0002-4922-2267

Augusto Weiand, IFRS, UFRGS, guto.weiand@gmail.com, 0000-0003-0117-1613
Eliseo Reategui, PPGIE/UFRGS, eliseoreategui@gmail.com, 0000-0002-5025-9710

Marcio Bigolin, IFRS, marcio.bigolin@canoas.ifrs.edu.br, 0000-0003-2315-9500
Regina Motz, UDELAR, rmotz@fing.edu.uy, 0000-0002-1426-562X

Resumo: O artigo discute a importância da escrita para a expressão e comunicação, enfocando seu papel no desenvolvimento escolar e social dos estudantes em todas as fases educacionais. A utilização da analítica de aprendizagem, impulsionada pelo progresso tecnológico, oferece uma oportunidade para compreender e enfrentar desafios na aprendizagem da escrita de maneira mais eficaz. O estudo apresentado discute o avanço da analítica de aprendizagem, destacando o surgimento da analítica da escrita como um campo especializado. Os dados da pesquisa foram coletados de trabalhos de alunos universitários e analisados por meio de métricas do NILC-Metrix, revelando uma correlação significativa entre a maioria das métricas e os conceitos atribuídos aos trabalhos. O estudo contribui para a compreensão de indicadores que podem estar relacionados à qualidade textual e enfatiza o interesse em explorar possibilidades de orientação de práticas pedagógicas com base nesses indicadores.

Palavras-chave: Analítica de aprendizagem, Ensino da escrita; Analítica da escrita

Writing Analytics for Identifying Indicators of Textual Quality

Abstract: The article discusses the importance of writing for expression and communication, emphasizing its role in the academic and social development of students at all educational stages. The use of learning analytics, driven by technological advancements, provides an opportunity to understand and address challenges in writing instruction more effectively. The presented study discusses the advancement of learning analytics, highlighting the emergence of writing analytics as a specialized field. Research data were collected from university students' works and analyzed using metrics from NILC-Metrix, revealing a significant correlation between most metrics and the assigned grades. The study contributes to the understanding of indicators that may be related to textual quality and emphasizes the interest in exploring possibilities for guiding pedagogical practices based on these indicators.

Keywords: Learning analytics, Writing instruction; Writing analytics

1. Introdução

A escrita, sendo uma habilidade fundamental para a expressão e comunicação, desempenha um papel crucial no desenvolvimento acadêmico e social dos estudantes em todas as etapas escolares. Contudo, muitos alunos enfrentam desafios significativos ao longo de sua jornada educacional, desde a formação das habilidades básicas de escrita até a complexidade exigida em níveis mais avançados. Tais dificuldades podem afetar não apenas o desempenho escolar, mas também a confiança e a participação ativa na sociedade (Sweeny, 2010). Com o avanço da tecnologia e a evolução da analítica de aprendizagem (do inglês *learning analytics*), surge uma oportunidade para compreender e abordar essas dificuldades de maneira mais eficaz. Ao empregar ferramentas analíticas para analisar as atividades de escrita dos alunos, torna-se possível identificar padrões, lacunas e estratégias de intervenção que possam apoiar a aprendizagem da escrita, em diferentes níveis.

Leitner et al. (2017) publicaram uma revisão sistemática de literatura que mostra como a analítica de aprendizagem vem sendo utilizada, com destaque para alguns enfoques, como o uso de MOOCs para compreender aspectos relacionados à aprendizagem e comportamento dos estudantes. Sousa et al. (2021) publicaram outra revisão de literatura com o foco distinto, no ensino médio, mostrando o predomínio de estudos relativos à predição de resultados de aprendizagem, ao invés do suporte ao ensino e à aprendizagem, ou na compreensão do comportamento dos estudantes. Quando o foco do estudo se concentra no uso de ferramentas de analítica de aprendizagem para a análise da escrita, o escopo e o número de trabalhos publicados torna-se menor. Neste contexto, surge também um termo específico que é a analítica da escrita, do inglês *writing analytics*, como um campo que se concentra na mensuração e análise de textos para compreender os processos e produtos de escrita em contextos educacionais (Lang et al., 2019). Dentro da analítica da escrita, três categorias de uso foram identificadas:

- Descritivo: busca-se revelar características dos textos para distintos tipos de escrita, como as diferenças de textos entre áreas, estilos ou níveis de escrita.
- Preditivo: busca-se realizar uma análise de textos para prever o desempenho de um indivíduo em uma tarefa de escrita futura.
- Prescritivo: busca-se identificar as dificuldades de escrita de um indivíduo para que possam ser fornecidos conselhos sobre o uso da linguagem ou para alterar algum aspecto de sua escrita, visando aprimorar seu desempenho.

A pesquisa aqui apresentada teve como foco o uso descritivo da analítica de aprendizagem. Neste contexto, embora tenha havido um aumento nos esforços em torno da implementação de soluções computacionais voltadas ao apoio à escrita, a maior parte das propostas mantém o foco na avaliação de problemas como erros de grafia, sintaxe ou gramática, sendo menor a atenção dada ao desenvolvimento de ferramentas voltadas ao acompanhamento e qualificação do processo da escrita, ou ainda sua avaliação (Strobl et al. 2019). Neste trabalho, discutimos o uso da Analítica da Escrita para identificar indicadores de produção textual que podem estar relacionados à qualidade do texto. Isso permite que os professores utilizem tais informações para orientar suas práticas pedagógicas e ajudar os alunos a aprimorar suas habilidades de escrita. O foco do trabalho desenvolvido foi a escrita acadêmica, no ensino superior. No entanto, os resultados apresentados certamente podem orientar o uso de tais técnicas para apoiar atividades discentes de ensino da escrita em outras etapas escolares.

2. Analítica de Aprendizagem e Analítica da Escrita

Nas últimas décadas, houve um aumento expressivo no número de estudantes em atividades educacionais online, resultando na geração de grandes quantidades de dados, especialmente por meio de Ambientes Virtuais de Aprendizagem (AVAs) (Almosallam e Ouertani, 2014). Esses dados representam uma importante fonte de informação, capazes de informar práticas pedagógicas com vistas ao aprimoramento do processo de aprendizagem, permitindo uma compreensão detalhada das atividades dos estudantes, como envio de tarefas, participação em fóruns e discussões, e produção textual (Siemens, 2013).

É nesse contexto que se concentra o campo da Analítica de Aprendizagem. Por meio de técnicas de análise de dados, estatísticas, mineração de dados e sistemas de informação, busca-se obter insights sobre o comportamento dos alunos em diferentes ambientes e contextos de aprendizagem (Almosallam e Ouertani, 2014). Por meio dessas técnicas busca-se coletar dados de diversas fontes, processá-los e visualizá-los de diferentes modos, proporcionando uma compreensão aprimorada do processo de aprendizagem para todos os envolvidos. Neste sentido, tanto a Analítica de Aprendizagem quanto a Analítica da Escrita envolvem a análise de dados relacionados à aprendizagem dos alunos. No entanto, a Analítica

da Escrita direciona seu foco especificamente para o acompanhamento do processo de produção textual, buscando possibilitar uma visão mais detalhada do progresso dos alunos em relação a suas habilidades de escrita. Neste âmbito, o Processamento de Linguagem Natural (PLN) desempenha um papel importante, dispondo de técnicas para classificação textual com base em características linguísticas (McNamara et al., 2014).

A maior parte dos estudos envolvendo PLN na análise e avaliação textual se concentra no idioma inglês, o que implica a necessidade de adaptações para o contexto da língua portuguesa. Dentre as diversas aplicações dessas tecnologias, a avaliação do nível de legibilidade e complexidade dos textos tem certo destaque, visando direcioná-los para a etapa escolar e/ou nível de compreensão apropriado (Xia et al, 2016; Pires et al., 2017). Além disso, a simplificação de conteúdos textuais para diferentes faixas etárias também é corrente, buscando garantir que o material seja acessível e envolvente para estudantes em diversos estágios de desenvolvimento da leitura (Crossley et al, 2012; Aluísio et al., 2010). Contudo, ainda são poucos os estudos com enfoque no uso de métricas textuais para avaliar qualidade textual, especialmente em língua portuguesa. Um desses estudos foi realizado por Evers e Finatto (2016). As autoras utilizaram aprendizado de máquina e processamento de linguagem natural para distinguir níveis de proficiência do português brasileiro, com base em padrões lexicais e coesivos. O trabalho mostrou como um conjunto de métricas, obtidas pelo uso do Coh-Matrix-Port, demonstrou comportamento não aleatório para as categorias estabelecidas. Uma árvore de decisão capaz de classificar os trabalhos nessas categorias foi implementada com uso da ferramenta Weka, demonstrando no entanto uma baixa capacidade de classificação. Já Martins (2016) realizou um estudo sobre a correlação entre indicadores de complexidade textual e desempenho acadêmico. Os resultados indicaram que, em relação à complexidade léxica, houve uma correlação positiva entre a frequência de substantivos e a progressão, e uma correlação negativa entre a frequência de verbos e a progressão. No que diz respeito à complexidade sintática, a correlação variou de acordo com o tipo de oração subordinada nos dois conjuntos de dados analisados. Vanhove et al. (2019) examinaram como as percepções dos leitores sobre a riqueza léxica de textos curtos podem ser previstas com base em índices computáveis automaticamente. Eles analisaram mais de 3.000 textos em francês, alemão e português, escritos por crianças de 8 a 10 anos. Descobriram que as avaliações podiam ser previstas em grande parte por meio desses índices, tanto em textos curtos quanto em textos mais longos. Já Oliveira et al. (2023) utilizaram modelos de regressão baseados em métodos convencionais de aprendizado de máquina e em modelos de linguagem pré-treinados de aprendizado profundo para estimar automaticamente a coesão de redações em português e inglês. Realizaram a análise de 4.570 redações em português e 7.101 em inglês, constatando que um modelo de aprendizado profundo teve o melhor desempenho, com uma correlação moderada de Pearson com as pontuações de coesão avaliadas por humanos. No entanto, a explicabilidade das estimativas automáticas de coesão com base em modelos convencionais de aprendizado de máquina mostrou um potencial maior do que o modelo de aprendizado profundo. Cavalcanti et al. (2020) procuraram identificar as características textuais mais influentes em textos de feedback escritos por professores, buscando prever sua qualidade. Um classificador foi treinado e avaliado, em língua portuguesa, em vários níveis de feedback. A variável mais importante identificada foi o número de parágrafos, diretamente ligada à quantidade de informações corretivas destinadas aos alunos, considerando o propósito do feedback em fornecer correções. Além disso, a contagem de pronomes por frase, enfatizando o uso predominante de pronomes pessoais de segunda pessoa pelos instrutores ao se referirem aos alunos, também destacou-se como característica relevante. Outras variáveis preditivas foram obtidas a partir da contagem de advérbios e mecanismos cognitivos, estando estas relacionadas à riqueza de detalhes nos textos dos instrutores em mensagens de feedback.

Os trabalhos acima descritos buscam mostrar, ainda de modo preliminar, como as métricas de análise textual baseadas em processamento de linguagem natural podem compor indicadores de qualidade de um texto. No entanto, não mostram com clareza o potencial do uso dessas métricas na composição do feedback formativo por parte dos professores. Esse é um dos principais objetivos desta pesquisa.

3. Métricas de análise e a ferramenta NILC-METRIX

O NILC-Matrix¹ consiste em um conjunto de funções baseadas nos princípios do Processamento de Linguagem Natural e da Linguística Computacional, destinado a fornecer métricas para a análise de textos em língua portuguesa (Leal, 2022). Essas funcionalidades foram concebidas no Núcleo Interinstitucional de Linguística Computacional (NILC), da Universidade de São Paulo. Originariamente, essas funções analíticas foram desenvolvidas com base em um conjunto preexistente denominado Coh-Matrix (McNamara e Graesser, 2012).

O NILC-Matrix engloba um total de 200 métricas, com o propósito de oferecer indicadores para avaliação multidimensional de um texto, considerando critérios como coesão, coerência e complexidade textual. A ferramenta já foi aplicada em diversas pesquisas nesse campo, como no projeto Adole-sendo (Leal et al., 2023), cujo objetivo era avaliar os fatores biopsicossociais que impactam o desenvolvimento do comportamento de adolescentes (com idades entre 9 e 15 anos), levando em consideração medidas de maturação biológica. No âmbito desse projeto, a idade cronológica e notas correlatas foram utilizadas para treinar um preditor de complexidade das narrativas produzidas pelos adolescentes, estabelecendo assim uma base para a pesquisa.

Outro exemplo de aplicação do NILC-Matrix é o corpus Leg2Kids (Leal et al., 2023), que contribuiu para a composição de funcionalidades dessa ferramenta. O corpus foi formado por 36.413 legendas de filmes e séries dos gêneros Família e Animação em Português do Brasil, disponibilizadas pela Open Subtitles em 2019. O corpus passou por um processo de pré-processamento para remover os marcadores de tempo presentes em cada legenda, os quais definem o intervalo de tempo em que uma legenda será exibida na tela. Posteriormente, o corpus foi segmentado em frases e transformado em tokens utilizando a ferramenta NLTK. O resultado foi um total de 153.791.083 tokens e 452.312 tipos.

Estes estudos mostram um enfoque voltado principalmente à identificação de indicadores da facilidade de leitura dos textos, com aplicações diretas relativas à classificação de textos para diferentes etapas escolares ou diferentes tipos de leitores. O uso de tais métricas para explorar a possibilidade de seu uso como indicadores de qualidade textual, como apoio à atividade docente, por exemplo, não é tão corrente. Este é o principal enfoque da pesquisa aqui apresentada.

5. Metodologia

O estudo aqui apresentado buscou identificar de que modo características textuais obtidas por meio de funções de processamento de linguagem natural estão relacionadas ao julgamento humano, mais propriamente as avaliações de produções escritas feitas pelo professor. A pesquisa se enquadra em uma abordagem quantitativa, com questões de investigação com características descritivas.

Os dados processados foram extraídos de projetos de pesquisa produzidos por alunos de nível de graduação em disciplinas de metodologia científica oferecidas a diferentes cursos

¹ A ferramenta NILC-Matrix está disponível em: <http://fw.nilc.icmc.usp.br:23380/nilcmatrix>. Acesso em 9 out. 2023.

de licenciatura. Foram coletados 206 trabalhos de 23 turmas semestrais entre os anos de 2019 e 2023. Os trabalhos continham avaliações com os conceitos A (ótimo), B (bom) e C (regular). Não havia trabalhos com conceitos D (insuficiente) na amostra.

Após a coleta dos dados, todos os trabalhos foram submetidos ao pacote de funções de análise textual NILC-Metrix. No contexto deste estudo, foram usadas 8 das 200 métricas disponibilizadas. A escolha dessas métricas se baseou em estudos anteriores que identificaram sua correlação com avaliações de professores quanto à qualidade textual de textos escritos em primeira e segunda língua (Crossley & McNamara, 2011). No caso do trabalho aqui apresentado, foram tomadas somente as métricas avaliadas no contexto da escrita em primeira língua. O quadro 1 mostra a categorização e descrição de cada métrica.

Quadro 1: Métricas para identificação de características linguísticas e comparação com avaliações de qualidade de escrita

Grupo	Métrica	Resumo
Sofisticação Léxica	Diversidade léxica	Proporção de palavras sem repetições (types) em relação ao total de palavras com repetições (tokens). Não se usa lematização das palavras, ou seja, cada flexão é computada como um tipo diferente.
	Frequência de palavras	Média das frequências absolutas das palavras de conteúdo do texto, via Banco de Português. Frequência absoluta é a quantidade de vezes que uma palavra ocorre em um corpus, considerando palavras de conteúdo como substantivos, verbos, adjetivos e advérbios.
	Nível de concretude das palavras	Identificam-se as palavras de conteúdo do texto. Em seguida, lematizam-se essas palavras, usando o DELAF, e procuram-se seus respectivos valores de concretude em um banco de dados específico para isso. Calcula-se a média desses valores.
	Polisemia das palavras	Média de sentidos por palavra de conteúdo do texto, a quantidade de sentidos é o número de sentidos que uma palavra tem no dicionário TEP (Thesaurus Eletrônico do Português).
Complexidade sintática	Palavras antes do verbo principal	Quantidade média de palavras antes dos verbos principais das orações principais das sentenças.
	Modificadores por sintagma nominal	Média dos tamanhos médios dos sintagmas nominais nas sentenças. Como há sintagmas nominais constituídos de outros sintagmas nominais, são computados apenas os de alto nível, ou seja, os mais próximos da raiz da árvore sintática.
Dispositivos de coesão	Conectivos Lógicos Positivos	Proporção de conectivos causais positivos em relação ao total de palavras do texto
	Sobreposição de palavras de conteúdo	Quantidade média de palavras de conteúdo que se repetem nos pares de sentenças adjacentes do texto.

Buscou-se compreender, no estudo desenvolvido, em que medida as métricas de análise textual descritas no Quadro 1 poderiam estar relacionados com avaliações feitas para trabalhos escritos em língua portuguesa. Para verificar a existência destas relações, utilizou-se o NILC-Metrix para cálculo das referidas métricas.

6. Resultados e Discussão

A Tabela 1 apresenta um conjunto de estatísticas descritivas (médias e desvios padrão) para cada métrica em relação aos conceitos A, B e C atribuídos aos 206 trabalhos utilizados neste estudo.

Tabela 1: Média e desvio padrão (DP) para cada métrica considerando

Métricas	Total		Conceito A		Conceito B		Conceito C	
	Média	DP	Média	DP	Média	DP	Média	DP
<i>Diversidade léxica</i>	1,0184	0,3412	1,0679	0,35933	0,8756	0,3495	0,7994	0,2299
<i>Frequência de palavras</i>	62193	41262	639341	342825	583101	659233	482072	198519
<i>Concretude das palavras</i>	6,8367	4,3544	7,6121	4,84866	4,8042	2,1064	4,3561	1,2123
<i>Polisemia das palavras</i>	7,1265	4,2936	7,8604	4,78803	5,17631	2,1735	4,7352	1,4087
<i>Palavras antes do verbo principal</i>	10,4127	7,1932	11,5170	7,95358	7,5796	4,4333	6,6524	2,2121
<i>Modificadores por sintagma nominal</i>	10,9012	7,5526	12,2397	8,36910	7,6144	3,7672	6,2996	2,2827
<i>Conectivos Lógicos Positivos</i>	0,06838	0,0268	0,0705	0,02268	0,06023	0,0263	0,0590	0,0284
<i>Sobrep. palavras de conteúdo</i>	1,85105	2,1187	2,0134	2,43020	1,45426	1,0095	1,20915	0,6229

Os resultados apresentados na Tabela 1 revelam uma diminuição nas médias das métricas em relação aos conceitos A, B e C, respectivamente. Essa tendência está alinhada às descobertas de Graesser & McNamara (2011), com exceção das métricas de *Frequência de Palavras*, *Conectivos Lógicos Positivos* e *Sobreposição de Palavras*. Para essas três métricas, os autores encontraram uma correlação inversa positiva entre as métricas e as avaliações atribuídas aos trabalhos. Isso sugere a possibilidade de diferentes tendências no efeito que essas características textuais podem ter nas avaliações dos trabalhos.

Para verificar a existência de relações estatisticamente significativas entre as métricas mencionadas e as avaliações dos 206 trabalhos escritos em língua portuguesa, foi realizada a análise de variância (ANOVA) entre as métricas calculadas para os trabalhos e os grupos definidos pelas categorias de conceito (A, B e C). Esse procedimento foi realizado para determinar se as diferenças observadas eram estatisticamente significativas, permitindo concluir se as variáveis independentes estão relacionadas à variável categórica 'conceito'. Os resultados estão apresentados na Tabela 2.

Tabela 2: Resultados para cálculos de ANOVA para cada métrica em relação aos conceitos A, B e C

	Média	Desvio Padrão	F-Value	P-Value	Eta ²
<i>Diversidade léxica</i>	1,0184	0,3412	9,993	< 0,001	0,0908
<i>Frequência de palavras</i>	62193	41262	1,5172	< 0,221	0,0149
<i>Concretude das palavras</i>	6,8367	4,3544	11,0320	< 0,001	0,0993
<i>Polisemia das palavras</i>	7,1265	4,2936	10,3343	< 0,001	0,0936
<i>Palavras antes do verbo principal</i>	10,4127	7,1932	8,1911	< 0,001	0,0757
<i>Modificadores por sintagma nominal</i>	10,9012	7,5526	10,9046	< 0,001	0,0983
<i>Conectivos Lógicos Positivos</i>	0,06838	0,0268	3,5378	< 0,03	0,0341
<i>Sobrep. palavras de conteúdo</i>	1,8510	2,1187	2,0977	< 0,1	0,0205

Os resultados obtidos revelaram relações estatisticamente significativas para a maioria das métricas, com valores de *p-value* substancialmente inferiores a 0,01, um limite comumente estabelecido na determinação de significância estatística. No entanto, as três métricas que não estavam alinhadas com os resultados encontrados anteriormente na literatura para análises textuais em língua inglesa não demonstraram resultados estatisticamente significativos. Para as métricas de *Frequência de Palavras* (*p-value* < 0,221), *Conectivos Lógicos Positivos* (*p-value* < 0,03) e *Sobreposição de Palavras de Conteúdo* (*p-value* < 0,1), não foi observada uma relação direta com as avaliações atribuídas aos trabalhos da amostra.

Analisando-se cada categoria separadamente, para a *Sofisticação Léxica* foi observada uma tendência de atribuição de avaliações mais altas para os projetos de pesquisa em que as métricas foram mais elevadas, a saber *Diversidade léxica*, *Concretude de palavras* e *Polisemia das palavras*. Para a métrica *Frequência de Palavras* não houve significância estatística. Logo, não foi possível atribuir nenhuma relação quanto a mudanças na frequência das palavras e os conceitos atribuídos. Mesmo assim, considerando-se as demais métricas, ainda é possível afirmar a tendência de que trabalhos com maior complexidade léxica tendam a obter avaliações superiores, mesmo sendo de mais difícil compreensão.

Quanto à *Complexidade Sintática*, os resultados mostraram-se alinhados àqueles reportados na literatura para análises em língua inglesa (Graessner e McNamara, 2011). Ou seja, o aumento nas métricas associadas à *Complexidade Sintática* mostrou relação estatisticamente significativa com o aumento dos conceitos dos trabalhos. Portanto, sentenças com estrutura mais complexa tenderam a influenciar positivamente a atribuição de conceitos.

No caso da categoria *Dispositivos de Coesão*, Graessner e McNamara (2011) reportaram relação inversa entre o aumento no uso destes dispositivos e as pontuações dos trabalhos, apontando que algumas vezes o aumento da coesão pode ser um preditor negativo da qualidade do texto. Na análise dos trabalhos aqui realizada, não observaram-se resultados significativos para a relação entre as métricas calculadas para a categoria e os conceitos atribuídos aos trabalhos. Neste sentido, as tendências apontadas por Graessner e McNamara (2011) não foram observadas para os trabalhos analisados em língua portuguesa, o que pode estar associado à diferença no tipo de texto analisado ou a características das próprias línguas dos textos. Neste sentido, entende-se a necessidade de novos estudos para melhor explorar as

tendências entre o uso de dispositivos de coesão e a pontuações atribuídas aos textos em língua portuguesa.

7. Conclusão

Este artigo apresentou um estudo sobre como diferentes métricas de análise textual obtidas por meio de processamento de linguagem natural se relacionam com as avaliações de projetos de pesquisa de graduação em língua portuguesa. Os resultados da pesquisa revelaram uma tendência na atribuição de conceitos mais elevados para trabalhos com maior sofisticação lexical e complexidade sintática. Esses achados corroboram resultados de estudos anteriores conduzidos em língua inglesa.

No entanto, os resultados relacionados ao uso de dispositivos de coesão não apresentaram significância estatística, diferindo de estudos anteriores que indicaram uma relação inversa entre a utilização de dispositivos coesivos e a atribuição de pontos em textos em língua inglesa. Estes resultados ressaltam a necessidade de novas pesquisas para uma compreensão mais aprofundada de como as métricas relacionadas à coesão podem servir como indicadores de qualidade em textos escritos em língua portuguesa, considerando possíveis diferenças em relação a outras línguas e gêneros textuais.

O estudo apresentado contribui com uma área de pesquisa identificada como carente na revisão sistemática da literatura de González-Calatayud et al. (2021). Nesta revisão, os autores ressaltaram a importância de investigar o uso de novas técnicas de inteligência artificial, incluindo mineração de textos/dados e processamento de linguagem natural, em processos de avaliação. Como direção para estudos futuros, propõe-se o desenvolvimento de ferramentas de visualização de dados que possam explorar ainda mais o potencial das métricas de análise textual com propósitos avaliativos. O objetivo principal é aprimorar a compreensão dos processos de aprendizagem da escrita, fornecendo aos professores informações que lhes permitam identificar e abordar as dificuldades dos alunos por meio de práticas pedagógicas específicas.

Referências

ALMOSALLAM, Entesar A.; OUERTANI, Henda Chorfi. Learning Analytics: definitions, applications and related fields. In: HERAWAN, T; DERIS, M; ABAWAJY, J (org.). *Lecture Notes in Electrical Engineering*. Cham: Springer Nature, 2013. p. 721–730. E-book. Disponível em: https://doi.org/10.1007/978-981-4585-18-7_81.

ALUISIO, Sandra et al. Readability Assessment for Text Simplification. In: NAACL HLT, 2010, Los Angeles, CA. *Fifth Workshop on Innovative Use of NLP for Building Educational Applications*. Los Angeles, CA: Association for Computational Linguistics, 2010. p. 1–9. Disponível em: <https://aclanthology.org/W10-1001.pdf>. Acesso em: 29 out. 2023.

CAVALCANTI, Anderson Pinheiro et al. How good is my feedback? In: LAK, 2020, Frankfurt, Alemanha. *Tenth International Conference on Learning Analytics & Knowledge*. New York: ACM, 2020. Disponível em: <https://doi.org/10.1145/3375462.3375477>.

CROSSLEY, Scott A.; ALLEN, David; MCNAMARA, Danielle S. Text simplification and comprehensible input: A case for an intuitive approach. *Language Teaching Research*, [s. l.], v. 16, n. 1, p. 89–108, 2011.

CROSSLEY, Scott A.; MCNAMARA, Danielle S. Understanding expert ratings of essay quality: Coh-Metrix analyses of first and second language writing. *International Journal of Continuing*

Engineering Education and Life-Long Learning, [s. l.], v. 21, n. 2/3, p. 170, 2011. Disponível em: <https://doi.org/10.1504/IJCEELL.2011.040197>. Acesso em: 29 out. 2023.

EVERS, Aline; FINATTO, Maria José Bocorny. Linguística de Corpus, Léxico-Estatística Textual e Processamento de Linguagem Natural: perspectiva para estudos de vocabulário em produções textuais. Revista GTLex, [s. l.], v. 1, n. 2, p. 271, 2016. Disponível em: <https://doi.org/10.14393/lex2-v1n2a2016-3>. Acesso em: 29 out. 2023.

GONZÁLEZ-CALATAYUD, Víctor; PRENDES-ESPINOSA, Paz; ROIG-VILA, Rosabel. Artificial Intelligence for Student Assessment: A Systematic Review. Applied Sciences, [s. l.], v. 11, n. 12, p. 5467, 2021. Disponível em: <https://doi.org/10.3390/app11125467>. Acesso em: 29 out. 2023.

LANG, Susan; AULL, Laura; MARCELLINO, William. A Taxonomy for Writing Analytics. The Journal of Writing Analytics, [s. l.], v. 3, n. 1, p. 13–37, 2019. Disponível em: <https://doi.org/10.37514/JWA-J.2019.3.1.03>. Acesso em: 29 out. 2023.

LEAL, Sidney Evaldo et al. NILC-Matrix: assessing the complexity of written and spoken language in Brazilian Portuguese. Language Resources and Evaluation, [s. l.], 2023. Disponível em: <https://doi.org/10.1007/s10579-023-09693-w>. Acesso em: 29 out. 2023.

LEITNER, Philipp; KHALIL, Mohammad; EBNER, Martin. Learning Analytics in Higher Education—A Literature Review. In: PEÑA-AYALA, A (org.). Learning Analytics: Fundamentals, Applications, and Trends. Cham: Springer, 2017. p. 1–23. E-book. Disponível em: <https://cmps-people.ok.ubc.ca/bowenhui/analytics/readings/overview2017.pdf>. Acesso em: 29 out. 2023.

MARTINS, Mário Gleisse das Chagas. Complexidade textual e progressão escolar em dois registos : um estudo de correlação baseado em um corpus quasi-longitudinal. 2016. Tese de doutorado, Universidade de Lisboa, 2016. Disponível em: <https://repositorio.ul.pt/handle/10451/23963>. Acesso em: 29 out. 2023.

MCNAMARA, Danielle S. et al. Automated Evaluation of Text and Discourse with Coh-Matrix. Cambridge: Cambridge University Press, 2014.

MCNAMARA, Danielle S; GRAESSER, Arthur C. Coh-Matrix An Automated Tool for Theoretical and Applied Natural Language . In: MCCARTHY, P; BOONTHUM-DENECKE, C (org.). IGI Global eBooks. [S. l.: s. n.], 2012. p. 188–205. E-book. Disponível em: <https://doi.org/10.4018/978-1-60960-741-8.ch011>. Acesso em: 29 out. 2023.

OLIVEIRA, Hilário et al. Towards explainable prediction of essay cohesion in Portuguese and English. In: LAK, 2023, Arlington, TX. 13th International Learning Analytics and Knowledge Conference. New York: Association for Computer Machinery, 2023. Disponível em: <https://doi.org/10.1145/3576050.3576152>. Acesso em: 29 out. 2023.

PIRES, Carla; CAVACO, Afonso; VIGÁRIO, Marina. Towards the Definition of Linguistic Metrics for Evaluating Text Readability. Journal of Quantitative Linguistics, [s. l.], v. 24, n. 4, p. 319–349, 2017. Disponível em: <https://doi.org/10.1080/09296174.2017.1311448>. Acesso em: 29 out. 2023.

SIEMENS, George. Learning Analytics. American Behavioral Scientist, [s. l.], v. 57, n. 10, p. 1380–1400, 2013. Disponível em: <https://doi.org/10.1177/0002764213498851>. Acesso em: 29 out. 2023.

SOUSA, Erverson B. G. de et al. Applications of Learning Analytics in High Schools: A Systematic Literature Review. Frontiers in Artificial Intelligence, [s. l.], v. 4, 2021. Disponível em: <http://doi.org/10.3389/frai.2021.737891>. Acesso em: 29 out. 2023.

STROBL, Carola et al. Digital support for academic writing: A review of technologies and pedagogies. *Computers & Education*, [s. l.], v. 131, p. 33–48, 2019. Disponível em: <https://doi.org/10.1016/j.compedu.2018.12.005>. Acesso em: 29 out. 2023.

SWEENEY, Sheelah M. Writing for the Instant Messaging and Text Messaging Generation: Using New Literacies to Support Writing Instruction. *Journal of Adolescent & Adult Literacy*, [s. l.], v. 54, n. 2, p. 121–130, 2010. Disponível em: <https://doi.org/10.1598/JAAL.54.2.4>. Acesso em: 29 out. 2023.

VANHOVE, Jan et al. Predicting human lexical richness ratings of short French, German, and Portuguese texts using text-based indices. *Journal of Writing Research*, [s. l.], v. 10, n. vol. 10 issue 3, p. 499–525, 2019. Disponível em: <https://doi.org/10.17239/jowr-2019.10.03.04>. Acesso em: 29 out. 2023.

XIA, Menglin; EKATERINA KOCHMAR; BRISCOE, Ted. Text Readability Assessment for Second Language Learners. In: BEA@ACL, 2016, San Diego, CA. 11th Workshop on Innovative Use of NLP for Building Educational Applications. [S. l.]: Association for Computational Linguistics, 2016. Disponível em: Acesso em: 15 out. 2023.