

<https://doi.org/10.56117/resbenq.2026.v7.e072621>

Metrologia e IA no ensino de Química Analítica em contextos sem laboratório

Metrology and Artificial Intelligence in Analytical Chemistry Education without Laboratory Infrastructure

Metrología e inteligencia artificial en la enseñanza de la Química Analítica en contextos con recursos limitados

Vitória H. C. de Freitas (vitoriahcdf@ufpi.edu.br)
Universidade Federal do Piauí
<https://orcid.org/0009-0006-8709-3482>

Maria M. S. Feitosa (maria.mariana@ufpi.edu.br)
Universidade Federal do Piauí
<https://orcid.org/0009-0005-2398-7375>

Henrique F. S. Neto (henriquefneto@ufpi.edu.br)
Universidade Federal do Piauí
<https://orcid.org/0009-0006-4089-3976>

Naise M. Caldas (naiseccaldas@ufpi.edu.br)
Universidade Federal do Piauí
<https://orcid.org/0000-0002-3977-3540>

Resumo

Este estudo investigou, no contexto do ensino de Química Analítica, o potencial de uma atividade experimental digital, fundamentada em princípios de metrologia e mediada por inteligência artificial (IA), para favorecer a aprendizagem significativa. A pesquisa foi realizada com 10 grupos de estudantes de uma disciplina de Química Analítica Instrumental da Universidade Federal do Piauí (UFPI) em um contexto caracterizado pela ausência de equipamentos laboratoriais, o que demandou uma estratégia de



Este texto é licenciado pela Creative Commons Attribution 4.0 International License.

experimentação acessível e centrada na análise de dados. Os estudantes realizaram medições indiretas de crescimento humano a partir de imagens digitais padronizadas, utilizando calibração por padrão interno (pixels→centímetros) com referência dimensional fixa, organização de dados em tabelas, construção de gráficos e modelagem por regressão linear pelo método dos mínimos quadrados. A qualidade das medições foi avaliada por meio do erro relativo percentual, adotando-se $ER \leq 3\%$ como critério de aceitabilidade didática, de modo a explicitar controle de repetibilidade e orientar a discussão sobre confiabilidade metrológica. A IA foi integrada como ferramenta de apoio à verificação de cálculos, checagem de coerência estatística, apoio à representação gráfica e à identificação de inconsistências, sempre sob mediação docente, com ênfase na validação conceitual e na não substituição do raciocínio analítico dos estudantes. Considerando o conjunto dos 10 grupos, a altura média estimada foi de 140,5 cm, com desvio padrão intergrupos de 4,0 cm; sete grupos atenderam ao critério $ER \leq 3\%$, e os ajustes lineares apresentaram R^2 médio = 0,988. Também foram observadas evidências qualitativas de compreensão conceitual sobre calibração, erro experimental e confiabilidade metrológica, expressas em justificativas, reconhecimento de fontes de erro e interpretação dos parâmetros do modelo. A comparação entre métodos de estimativa e a contextualização dos valores obtidos como referência analítica favoreceram a discussão sobre pressupostos, limites de extrapolação e impacto do controle de qualidade sobre a robustez dos resultados. Conclui-se que a integração entre experimentação digital, metrologia e IA configura uma alternativa viável, acessível e replicável para o ensino de Química Analítica em instituições públicas brasileiras, fortalecendo competências de tratamento de dados, pensamento crítico e tomada de decisão baseada em evidências em ambientes educacionais com restrições de infraestrutura.

Palavras-chave: Metrologia. Inteligência Artificial. Ensino de Química Analítica.

Abstract

This study investigated, within the context of Analytical Chemistry education, the potential of a digital experimental activity grounded in metrological principles and

mediated by artificial intelligence (AI) to promote meaningful learning. The research involved ten groups of undergraduate students enrolled in an Analytical Chemistry Instrumentation course at the Federal University of Piauí (UFPI), in a setting characterized by the absence of conventional laboratory infrastructure, which required the adoption of an accessible, data-centered experimental approach. Students performed indirect measurements of human growth using standardized digital images, applying internal standard calibration to convert pixel measurements into centimeters, organizing data into tables, constructing graphs, and developing linear regression models using the least squares method. Measurement quality was assessed through relative error percentage, with an a priori didactic acceptability criterion of $ER \leq 3\%$, explicitly addressing repeatability and metrological reliability. AI tools were integrated as supportive resources for verifying calculations, checking statistical consistency, generating graphical representations, and identifying inconsistencies, always under instructor mediation and without replacing students' analytical reasoning. Considering all ten groups, the mean estimated height was 140.5 cm, with an intergroup standard deviation of 4.0 cm; seven groups met the $ER \leq 3\%$ criterion, and the linear fits showed an average coefficient of determination (R^2) of 0.988. Qualitative findings demonstrated students' conceptual understanding of calibration, measurement error, and reliability, as evidenced by written justifications, recognition of random and systematic errors, and interpretation of regression parameters. Comparative analysis of estimation approaches and contextualization of results as analytical references supported critical discussion of model assumptions, extrapolation limits, and the impact of measurement quality on result robustness. Overall, the findings indicate that integrating digital experimentation, metrology, and artificial intelligence constitutes a viable, accessible, and replicable strategy for teaching Analytical Chemistry in public universities, enhancing students' data analysis skills, critical thinking, and evidence-based reasoning in resource-limited educational environments.

Keywords: Metrology. Artificial intelligence. Analytical Chemistry education.

Resumen

Este estudio tuvo como objetivo investigar, en el contexto de la enseñanza de la Química Analítica, el potencial de una actividad experimental digital, fundamentada en principios de metrología y mediada por inteligencia artificial, para promover el aprendizaje significativo. La investigación se desarrolló con diez grupos de estudiantes de una asignatura de Química Analítica Instrumental en la Universidad Federal de Piauí (UFPI), en un contexto caracterizado por la ausencia de infraestructura de laboratorio convencional, lo que exigió la adopción de una estrategia experimental accesible y centrada en el análisis de datos. La actividad consistió en la medición indirecta del crecimiento humano a partir de imágenes digitales estandarizadas, utilizando calibración por patrón interno para la conversión proporcional de píxeles a centímetros, organización de datos en tablas, construcción de gráficos y modelado mediante regresión lineal por el método de los mínimos cuadrados. La calidad metrológica de las mediciones se evaluó mediante el error relativo porcentual, estableciéndose previamente el criterio de aceptabilidad didáctica $ER \leq 3\%$, con el fin de explicitar la repetibilidad y la confiabilidad de las mediciones. Las herramientas de inteligencia artificial se integraron como recursos de apoyo para la verificación de cálculos, la comprobación de la coherencia estadística, la elaboración de representaciones gráficas y la identificación de inconsistencias, siempre bajo mediación docente y sin sustituir el razonamiento analítico de los estudiantes. Considerando los diez grupos, la altura media estimada fue de 140,5 cm, con una desviación estándar entre grupos de 4,0 cm; siete grupos cumplieron el criterio $ER \leq 3\%$, y los ajustes lineales presentaron un coeficiente de determinación promedio (R^2) de 0,988. El análisis cualitativo reveló comprensión conceptual sobre calibración, error experimental y confiabilidad de las mediciones, manifestada en justificaciones escritas, reconocimiento de errores aleatorios y sistemáticos e interpretación de los parámetros de regresión. La comparación entre diferentes métodos de estimación y la contextualización de los resultados como referencias analíticas favorecieron la discusión crítica sobre los supuestos de los modelos, los límites de extrapolación y el impacto de la calidad de las mediciones en la robustez de los resultados. Se concluye

que la integración entre experimentación digital, metrología e inteligencia artificial constituye una estrategia viable, accesible y replicable para la enseñanza de la Química Analítica en universidades públicas, fortaleciendo competencias de análisis de datos, pensamiento crítico y toma de decisiones basada en evidencias en contextos educativos con recursos limitados.

Palabras clave: Metrología. Inteligencia Artificial. Química Analítica.

Introdução

O ensino de Química Analítica em cursos de graduação em Ciências requer que os estudantes desenvolvam competências relacionadas à análise de dados, à estimativa de incertezas e à interpretação crítica de erros experimentais. No entanto, estudos clássicos e contemporâneos indicam que conceitos fundamentais da metrologia, como calibração, erro relativo, precisão, exatidão e incerteza, são frequentemente aprendidos de forma algorítmica e fragmentada, com fraca integração à prática científica autêntica (Harris, 2007; Skoog et al., 2007). Esse tipo de abordagem favorece o que Ausubel (1968) descreve como aprendizagem mecânica, caracterizada pela memorização de procedimentos sem ancoragem conceitual significativa. Em contraposição, a aprendizagem significativa ocorre quando novas informações se relacionam, de maneira substantiva e não arbitrária, a conhecimentos relevantes já existentes na estrutura cognitiva do estudante, possibilitando a reorganização e a ampliação dos significados atribuídos ao conhecimento (Ausubel, 1968; Moreira, 2011). No contexto do ensino de Química Analítica, essa perspectiva implica compreender conceitos como calibração, erro, regressão e confiabilidade das medidas não apenas como procedimentos de cálculo, mas como conhecimentos articulados às decisões tomadas durante o processo experimental.

A literatura em Educação em Química aponta que muitos estudantes apresentam dificuldades em atribuir significado científico a dados numéricos, especialmente em tarefas que envolvem conversão de unidades, construção de gráficos, ajuste de modelos matemáticos e identificação de erros sistemáticos e aleatórios em

conjuntos experimentais de dados (Galiazzi & Gonçalves, 2004; Krasilchik, 2008). Nesses cenários, medidas e resultados tendem a ser percebidos como valores isolados, e não como construções científicas dependentes de contexto, método e interpretação, evidenciando a necessidade de abordagens pedagógicas que articulem tratamento de dados, experimentação significativa e situações reais.

A experimentação didática constitui um recurso central para a promoção da aprendizagem significativa, ao possibilitar a articulação entre conhecimentos prévios e novos conceitos científicos por meio de situações-problema contextualizadas (Hodson, 1993; Krasilchik, 2008). No ensino de Química Analítica, atividades experimentais que envolvem coleta, análise e interpretação de dados reais funcionam como ponte entre conteúdos abstratos, como regressão linear, calibração instrumental e análise de incertezas, e fenômenos observáveis, favorecendo o desenvolvimento do pensamento crítico, da autonomia investigativa e da comunicação científica estruturada.

Nesse contexto, a incorporação de tecnologias digitais tem ampliado as possibilidades para o ensino de metrologia e análise instrumental (Skoog et al., 2007). Métodos baseados em imagens digitais vêm sendo empregados em diferentes aplicações educacionais, como fotogrametria e mensurações não invasivas, permitindo experimentos de baixo custo, alta acessibilidade e elevado potencial didático (Jarujareet et al., 2023; Santos, 2022). Quando integrados a ferramentas de inteligência artificial (IA), esses métodos podem oferecer suporte adicional à verificação de cálculos, à análise estatística e à interpretação gráfica dos dados, ampliando o rigor e a reflexividade do processo formativo (Iyamuremye, 2024; Kasneci et al., 2023).

Estudos recentes na área de Educação em Química indicam que ferramentas de inteligência artificial generativa podem contribuir para atividades de resolução de problemas, análise de informações e desenvolvimento do pensamento crítico, especialmente quando os estudantes são orientados a avaliar, verificar e justificar criticamente as respostas produzidas pelos sistemas de IA (Guo & Lee, 2023; Pence et al., 2024). Estudos com estudantes de Química também mostram que a simples utilização dessas ferramentas não garante aprendizagem, uma vez que estratégias pouco elaboradas de interação e aceitação acrítica das respostas podem limitar seus

benefícios educacionais, reforçando a importância da orientação e da mediação docente (Tassoti, 2024). Nesse sentido, a IA pode atuar como recurso de apoio à identificação de inconsistências, à revisão de procedimentos e à elaboração de explicações, desde que suas respostas sejam confrontadas com dados experimentais, conhecimentos científicos e critérios de validade.

Apesar do crescimento do interesse em aplicações educacionais da IA, ainda são escassos os estudos experimentais que integrem, de forma sistemática, metrologia, análise de imagens digitais e inteligência artificial como estratégias de aprendizagem no ensino de Química Analítica (Iyamuremye, 2024). Observa-se uma lacuna de investigações que apresentem evidências quantitativas e qualitativas sobre como essas abordagens contribuem para a compreensão de erro experimental, calibração de instrumentos digitais e interpretação de modelos de regressão, especialmente em contextos de instituições públicas com limitações de infraestrutura (Schnetzler, 2002).

Diante desse cenário, este estudo busca investigar como atividades experimentais digitais, baseadas em proporcionalidade e regressão linear e mediadas por inteligência artificial, podem promover aprendizagem significativa de metrologia no ensino de Química Analítica. A pergunta de pesquisa que orienta o trabalho é: como estudantes de Química Analítica tratam dados experimentais digitais, interpretam erros e utilizam a inteligência artificial como ferramenta analítica ao participar de uma atividade de medição de crescimento humano baseada em proporcionalidade e regressão linear?

O objetivo geral do estudo é investigar de que forma atividades experimentais digitais envolvendo proporcionalidade, conversão de unidades, regressão linear e uso de inteligência artificial contribuem para a aprendizagem significativa de metrologia na disciplina de Química Analítica Instrumental. Como objetivos específicos, pretende-se: (i) aplicar conceitos de proporcionalidade e conversão de pixels para centímetros utilizando uma referência visual fixa; (ii) construir gráficos e modelos de regressão linear pelo método dos mínimos quadrados; (iii) calcular e interpretar erros relativos, precisão e consistência estatística; (iv) comparar resultados experimentais com curvas referenciais de crescimento humano; (v) analisar o uso da IA como ferramenta de

apoio crítico no tratamento dos dados; e (vi) identificar evidências de aprendizagem significativa decorrentes da integração entre experimento digital, análise estatística e IA.

Metodologia

Tipo de estudo

O presente estudo caracteriza-se como uma pesquisa educacional de abordagem mista, de natureza descritivo-exploratória, desenvolvida a partir de uma intervenção didática realizada em contexto regular de ensino. A investigação combinou a análise estatística descritiva dos dados experimentais produzidos pelos estudantes com a análise qualitativa de suas produções escritas, registros reflexivos e observações realizadas durante a atividade. O estudo teve como finalidade compreender como os participantes mobilizaram conhecimentos de metrologia, estatística e análise crítica no desenvolvimento de uma atividade experimental digital mediada por tecnologias digitais e ferramentas de inteligência artificial, sem pretensão de estabelecer relações causais, realizar inferências populacionais ou proceder à validação normativa metrológica.

Contexto institucional e participantes


A pesquisa foi realizada na Universidade Federal do Piauí (UFPI), no âmbito da disciplina Química Analítica Instrumental, durante o semestre letivo 2025.2. Participaram do estudo 37 estudantes, organizados em 10 grupos de trabalho, todos submetidos às mesmas condições experimentais. As atividades ocorreram em sala de aula convencional, em contexto caracterizado pela ausência de equipamentos laboratoriais analíticos, sendo utilizados dispositivos móveis ou computadores pessoais como ferramentas digitais de medição, tratamento e análise de dados.

Procedimento experimental

Os estudantes analisaram uma sequência de imagens digitais ilustrativas, organizadas longitudinalmente e representando, de forma didaticamente controlada, o crescimento de uma criança em intervalos anuais simulados entre 2017 e 2024 (Figura 1). As imagens foram produzidas exclusivamente para fins educacionais, não

correspondendo a fotografias de indivíduos reais nem contendo qualquer elemento de identificação pessoal. Em todas as imagens, a criança foi representada utilizando a mesma vestimenta, cujo comprimento conhecido (50 cm) foi adotado como padrão interno de calibração. As imagens foram padronizadas quanto ao enquadramento frontal, postura ortostática e preservação do eixo vertical, minimizando distorções geométricas e variações sistemáticas associadas à perspectiva. A malha gráfica ao fundo foi utilizada apenas como recurso auxiliar de alinhamento visual, não interferindo nas medições.

Figura 1 - *Sequência de Imagens Digitais Ilustrativas Utilizadas na Atividade Experimental*



Nota. Imagens de 2017–2024 produzidas para fins educacionais e padronizadas quanto ao enquadramento frontal, postura ortostática e eixo vertical. A vestimenta de comprimento conhecido (50 cm) foi empregada como padrão interno para calibração proporcional das medidas em pixels para centímetros. A malha gráfica ao fundo foi utilizada exclusivamente como recurso auxiliar de alinhamento visual, sem interferir nas medições.

Os arquivos foram disponibilizados aos grupos em formato digital (JPG), organizados em pasta única e identificados por ano, assegurando uniformidade no acesso aos dados, rastreabilidade das medições e reprodutibilidade do procedimento.

Cada grupo realizou as medições digitais utilizando um único software gratuito (ImageMeter, Paint/Paint 3D, GIMP ou MeasureIt), mantido ao longo de todo o procedimento. Para cada imagem, os estudantes foram orientados a realizar três medições independentes do comprimento da vestimenta em pixels (Vpx) e da altura total da criança em pixels (Hpx), com reposicionamento manual do marcador a cada leitura. Entretanto, o número efetivamente registrado nos relatórios variou entre os grupos, conforme apresentado na Tabela 1. A repetibilidade foi avaliada por meio do erro relativo percentual, calculado conforme a Equação (1):

$$ER(\%) = \frac{|A-B|}{\left(\frac{A+B}{2}\right)} \times 100$$

em que A e B correspondem, respectivamente, aos valores máximo e mínimo das replicatas disponíveis para a grandeza analisada. Valores de $ER \leq 3\%$ foram considerados aceitáveis para fins didáticos. Nos casos em que foi registrada apenas uma medição, o ER% não foi calculado, uma vez que uma única observação não permite avaliar a repetibilidade da medida.

A conversão de pixels para centímetros foi realizada por proporcionalidade direta, utilizando a Equação (2):

A incerteza foi tratada de forma simplificada e pedagógica. Para as séries em que três replicatas estavam disponíveis, calcularam-se média aritmética e desvio-padrão, estimando-se a incerteza padrão da média por $u(\bar{x}) = s/\sqrt{n}$, com $n = 3$. A propagação de incertezas foi discutida qualitativamente, e a incerteza expandida foi expressa como $U = k \cdot u_c$, com $k \approx 2$, exclusivamente para fins educacionais.

Os dados convertidos foram organizados em tabelas e utilizados para construção de gráficos Altura (cm) $\times$ Idade (anos), com ajuste linear pelo método dos mínimos quadrados ($y = ax + b$). O coeficiente de determinação (R^2) foi adotado como indicador da qualidade do ajuste.

A projeção da altura aos 10 anos foi realizada por regressão linear e por crescimento médio anual, sendo a comparação entre métodos utilizada como critério de consistência metrológica. As alturas projetadas foram comparadas, de forma

exploratória e não diagnóstica, com referências de estatura por idade da Organização Mundial da Saúde para 5–19 anos e com as curvas de crescimento do CDC para 2–20 anos (World Health Organization, 2007; National Center for Health Statistics, 2002).

Ferramentas de inteligência artificial generativa foram integradas como apoio à verificação de cálculos, análise de coerência estatística e reflexão conceitual, sem geração automática de resultados, sempre sob mediação docente.

Instrumentos e análise dos dados

Foram utilizados dados quantitativos (medições, regressões e projeções) e qualitativos (relatórios, respostas abertas e observações em sala), permitindo triangulação metodológica. A análise quantitativa concentrou-se em estatísticas descritivas e consistência metrológica, enquanto a análise qualitativa seguiu princípios de análise de conteúdo, com categorização temática.

Aspectos éticos

O estudo foi conduzido em contexto de prática pedagógica regular, com dados anonimizados e agregados. Os estudantes foram informados sobre os objetivos da pesquisa e autorizaram o uso de suas produções para fins científicos, conforme orientações institucionais vigentes na UFPI.

Resultados

Caracterização dos grupos participantes

A atividade experimental foi desenvolvida por 37 estudantes da disciplina de Química Analítica Instrumental, organizados em 10 grupos de trabalho. A Tabela 1 apresenta a caracterização dos grupos quanto às ferramentas digitais empregadas nas medições em pixels e ao número de replicatas efetivamente registradas.

Tabela 1 - *Caracterização dos Grupos Participantes da Atividade Experimental*

Grupo	Ferramentas digitais utilizadas	Nº de replicatas registradas
1	Paint / ImageMeter	2
2	ImageMeter / GIMP / IA	2-3
3	Paint	2
4	Painel OMS/WHO + planilha	1-2
5	Paint × ImageMeter (comparação)	2
6	ImageMeter / IA	2
7	ImageMeter / IA	2
8	Paint / régua digital	2
9	ImageMeter	1-2
10	ImageMeter / IA	2

Nota. Quatro dos dez grupos utilizaram explicitamente ferramentas de inteligência artificial como apoio à verificação de cálculos, ajustes de regressão ou projeções numéricas. As diferenças no número de replicatas refletem decisões metodológicas adotadas pelos próprios grupos durante a execução da atividade.

Observa-se diversidade nas ferramentas utilizadas, incluindo softwares gráficos, aplicativos de medição digital e, em alguns casos, ferramentas de inteligência artificial empregadas como apoio à verificação de cálculos e ajustes numéricos. Também se verifica variação no número de replicatas realizadas entre os grupos, refletindo decisões metodológicas adotadas durante a execução da atividade. Essas diferenças foram consideradas nas análises subsequentes de consistência metrológica.

Dados brutos de medição em pixels e conversão proporcional

A Tabela 2 apresenta os valores médios das medições realizadas em pixels para o comprimento do vestido (V_{px}) e para a altura da criança (H_{px}), bem como os respectivos erros relativos percentuais (ER%), obtidos a partir de medições em duplicata ou triplicata, conforme descrito na Metodologia.

As medições foram realizadas diretamente sobre as imagens digitais ao longo do eixo vertical, preservando a proporcionalidade geométrica entre as grandezas analisadas. O

comprimento real do vestido (50 cm) foi utilizado como padrão interno de calibração, permitindo a conversão proporcional das medidas em pixels para centímetros.

Tabela 2 - Dados Brutos de Medição em Pixels e Conversão Proporcional para Centímetros

Grupo	Vpx médio (px)	Hpx médio (px)	ER (%)	Altura estimada (cm)*
1	298	842	2,8	141,3
2	274	772	1,2	140,9
3	310	910	3,5	146,8
4	281	780	2,1	138,8
5	290	842	6,9	145,2
6	300	840	1,4	140,0
7	295	830	1,0	140,7
8	302	820	3,9	135,8
9	289	770	2,3	133,2
10	297	845	1,7	142,2

Nota. Altura estimada calculada pela conversão proporcional descrita na Equação (2).


A maioria dos grupos apresentou valores de ER% dentro do critério de aceitabilidade didática previamente estabelecido ($ER \leq 3\%$). Três grupos exibiram valores superiores a esse limite, com destaque para o Grupo 5, que apresentou o maior erro relativo percentual (6,9%), indicando maior variabilidade associada às medições em pixels. Esses dados constituíram a base para as análises estatísticas e projeções apresentadas nas seções seguintes.

Modelagem estatística e regressões Altura $\times$ Idade

A relação entre a altura estimada e a idade foi analisada por meio de regressão linear simples, considerando os valores médios anuais obtidos a partir da conversão proporcional das medições em pixels para centímetros. Para cada grupo, foram construídos gráficos de dispersão Altura (cm) $\times$ Idade (anos), conforme descrito na Metodologia.

A Figura 2A apresenta a altura estimada aos 9 anos (2024) para cada grupo, expressa como média das replicatas internas $\pm$ desvio-padrão. Observa-se que 7 dos 10 grupos apresentaram valores concentrados entre aproximadamente 135 e 145 cm, com barras de erro reduzidas, enquanto alguns grupos exibiram maior dispersão associada à variabilidade experimental.

Figura 2A - *Altura Estimada aos 9 Anos por Grupo*



Nota. As barras de erro representam a dispersão das replicatas realizadas por cada grupo, evidenciando a variabilidade experimental associada ao processo de medição digital.

Os principais indicadores estatísticos intergrupos encontram-se sintetizados na Tabela 3, que reúne medidas de tendência central, dispersão e controle do erro relativo. O coeficiente de determinação médio dos ajustes lineares foi $R^2 = 0,988$, também sintetizado na Tabela 3. As projeções de altura obtidas pelos Métodos A e B são apresentadas na Tabela 4.

Tabela 3 - Estatística Descritiva Intergrupos das Alturas Estimadas aos 9 Anos e Controle de Erro Experimental

Parâmetro	Valor
Número de grupos	10
Altura média estimada (cm)	140,5
Desvio padrão intergrupos (cm)	4,0
Altura mínima (cm)	133,2
Altura máxima (cm)	146,8
Grupos com $ER \leq 3\%$	7
Grupos com $ER > 3\%$	3
R^2 médio dos ajustes lineares	0,988

Tabela 4 - Projeção da Altura da Criança aos 10 Anos (2025) Obtida pelos Métodos A e B

Grupo	Altura ₁₀ – Método A (cm)	Altura ₁₀ – Método B (cm)	$ \Delta $ (B – A) (cm)
1	141,8	143,2	1,4
2	139,5	140,1	0,6
3	144,2	147,9	3,7
4	138,9	139,6	0,7
5	150,3	157,1	6,8
6	142,0	143,4	1,4
7	140,8	141,5	0,7
8	136,9	139,8	2,9
9	139,2	140,4	1,2
10	142,5	143,0	0,5


De modo geral, os valores de R^2 foram elevados, com predominância de ajustes lineares fortes no intervalo etário analisado (2017–2024), evidenciando correlação linear consistente entre altura estimada e idade para a maioria dos grupos.

Projeção da altura aos 10 anos

A projeção da altura da criança aos 10 anos de idade (2025) foi realizada a partir dos modelos construídos com os dados experimentais obtidos no período de 2017 a 2024, utilizando dois métodos distintos: projeção por regressão linear (Método A) e projeção por crescimento anual médio (Método B).

Os valores projetados para cada grupo, bem como a diferença absoluta entre os métodos, estão apresentados na Tabela 4. As projeções obtidas pelos dois métodos mostraram, em geral, diferenças moderadas, variando conforme o controle metrológico das medições e os pressupostos estatísticos adotados.

Figura 2B - *Comparação entre os Valores de Altura Projetados aos 10 Anos pelos Métodos A e B*



Nota. O Método A corresponde à regressão linear e o Método B ao crescimento anual médio. A linha tracejada representa a identidade ($y = x$); a proximidade dos pontos à linha indica concordância entre os métodos.

A Figura 2B apresenta a comparação direta entre os valores projetados pelos Métodos A e B, na forma de um gráfico de dispersão Método B $\times$ Método A, incluindo a linha identidade ($y = x$). A proximidade dos pontos em relação à linha identidade indica concordância entre os métodos, enquanto desvios mais pronunciados refletem diferenças associadas às características dos conjuntos de dados e às abordagens de projeção.

Comparação com percentis de crescimento da OMS

As alturas projetadas para a criança aos 10 anos de idade pelo Método A, baseado em regressão linear, foram comparadas, de forma exploratória, com a referência de estatura por idade da Organização Mundial da Saúde (OMS) para meninas de 10 anos completos. Para essa idade, foram considerados, como referências aproximadas, os percentis P3 = 126,6 cm, P15 = 132,0 cm, P50 = 138,6 cm, P85 = 145,3 cm e P97 = 150,7 cm.

A Tabela 5 apresenta a classificação percentílica aproximada das alturas projetadas pelo Método A para cada grupo. De modo geral, nove dos dez grupos apresentaram projeções entre os percentis P15 e P85, com predominância de valores entre P50 e P85. O Grupo 5 apresentou a maior projeção, situando-se entre os percentis P85 e P97. Essa comparação foi utilizada exclusivamente como recurso pedagógico para contextualização das estimativas produzidas pelo modelo, sem finalidade diagnóstica.

Tabela 5 - Classificação das Alturas Projetadas pelo Método A aos 10 Anos Segundo Referência de Crescimento da OMS

Grupo	Altura projetada pelo Método A (cm)	Classificação percentílica aproximada
1	141,8	P50-P85
2	139,5	P50-P85
3	144,2	P50-P85

Grupo	Altura projetada pelo	Classificação percentílica
	Método A (cm)	aproximada
4	138,9	P50-P85
5	150,3	P85-P97
6	142,0	P50-P85
7	140,8	P50-P85
8	136,9	P15-P50
9	139,2	P50-P85
10	142,5	P50-P85

Nota. Classificação aproximada baseada na referência de estatura por idade da Organização Mundial da Saúde para meninas de 10 anos completos. Foram considerados como referências P3 = 126,6 cm, P15 = 132,0 cm, P50 = 138,6 cm, P85 = 145,3 cm e P97 = 150,7 cm. Os valores são utilizados exclusivamente para fins pedagógicos e não possuem finalidade diagnóstica.

Distribuição dos erros relativos percentuais

A distribuição dos erros relativos percentuais (ER%) associados às medições em pixels foi analisada como indicador da repetibilidade e da qualidade metrológica do procedimento experimental. Os valores médios de ER% por grupo estão apresentados na Tabela 6.

Tabela 6 - Erros Relativos Percentuais (ER%) Associados às Medições em Pixels Realizadas pelos Diferentes Grupos


Grupo	Vpx (px)	Hpx (px)	ER (%)
1	298	842	2,8
2	274	772	1,2
3	310	910	3,5
4	281	780	2,1
5	290	842	6,9
6	300	840	1,4
7	295	830	1,0

Grupo	Vpx (px)	Hpx (px)	ER (%)
8	302	820	3,9
9	289	770	2,3
10	297	845	1,7

Nota. ER (%) calculado a partir das replicatas de leitura conforme a Equação (1). Valores de $ER \leq 3\%$ foram considerados aceitáveis para fins didáticos.

A Figura 3 ilustra a distribuição gráfica dos erros relativos percentuais entre os grupos, evidenciando a predominância de valores dentro do critério de aceitabilidade didática ($ER \leq 3\%$) e a presença de poucos casos com maior dispersão. Esses resultados refletem a heterogeneidade controlada esperada em atividades educacionais baseadas em medições manuais.

Figura 3 - Distribuição dos Erros Relativos Percentuais (ER%) entre os Grupos Participantes



Nota. A linha tracejada indica o critério didático de aceitabilidade $ER = 3\%$.

Classificação dos tipos de erros experimentais

Além da quantificação dos erros relativos percentuais, procedeu-se à identificação e classificação dos tipos de erros experimentais explicitamente relatados pelos grupos em seus relatórios. A análise permitiu agrupar os erros em categorias amplamente reconhecidas na literatura de metrologia: erros aleatórios e erros sistemáticos.

Tabela 7 - *Classificação dos Tipos de Erros Experimentais Relatados pelos Grupos Participantes e Frequência de Ocorrência*

Tipo de erro	Descrição resumida	Frequência (nº de grupos)
Erro aleatório – marcação	Variação na escolha dos pontos inicial/final da régua	8
Erro aleatório – repetibilidade	Diferenças entre replicatas sucessivas	7
Erro sistemático – postura	Alterações na posição corporal nas imagens	5
Erro sistemático – perspectiva	Inclinação ou distorção do eixo vertical	6
Erro operacional	Uso inadequado da ferramenta digital	3
Ausência de controle explícito	Não identificação consciente de erros	2

Nota. Um mesmo grupo pode ter relatado mais de um tipo de erro.

A Tabela 7 apresenta a categorização dos tipos de erro relatados e a frequência de ocorrência entre os grupos. Os erros aleatórios estiveram associados principalmente à variabilidade na marcação manual dos pontos de medição e às diferenças entre replicatas sucessivas. Os erros sistemáticos estiveram relacionados a fatores geométricos, operacionais e de enquadramento das imagens.

Síntese dos dados qualitativos

Os dados qualitativos obtidos a partir dos relatórios escritos, registros reflexivos e observações em sala foram sintetizados por meio de análise de conteúdo. As categorias emergentes estão apresentadas na Tabela 8, incluindo compreensões

conceituais adequadas, dificuldades recorrentes, percepções sobre o uso de inteligência artificial e evidências de aprendizagem significativa.

De forma descritiva, observou-se que a maioria dos grupos demonstrou compreensão adequada da proporcionalidade na conversão de pixels para centímetros e reconheceu a importância do controle de erros experimentais. Também foram registradas dificuldades pontuais na interpretação conceitual de parâmetros estatísticos e no uso reflexivo de ferramentas de inteligência artificial.

Tabela 8 - Síntese das Categorias Qualitativas Emergentes a partir da Análise dos Relatórios e Registros dos Estudantes

Categoria analítica	Evidências observadas
Compreensões conceituais adequadas	Aplicação correta da proporcionalidade na conversão de pixels para centímetros; uso apropriado da regressão linear para modelagem do crescimento; comparação coerente dos resultados com curvas normativas da OMS/CDC; identificação explícita de fontes de erro experimental.
Dificuldades conceituais recorrentes	Limitações na explicação da origem física e geométrica de erros sistemáticos; interpretação incompleta do significado do coeficiente de determinação (R^2); dificuldade em justificar conceitualmente as diferenças entre os Métodos A (regressão linear) e B (crescimento anual médio).
Percepções sobre o uso de Inteligência Artificial	Reconhecimento da IA como ferramenta útil para validação de cálculos e verificação de coerência numérica; percepção do risco de dependência excessiva; maior clareza na checagem de resultados do que na interpretação conceitual dos modelos.
Evidências de aprendizagem significativa	Produção de explicações próprias e não meramente algorítmicas; ancoragem entre conceitos matemáticos e fenômenos físicos reais; identificação intuitiva e progressivamente consciente de erros metrológicos e limitações do método experimental.

Discussão

Metrologia, controle de qualidade e aprendizagem conceitual

Os resultados indicam que a explicitação de um critério metrológico de qualidade ($ER \leq 3\%$) desempenhou papel central na obtenção de estimativas consistentes e estatisticamente coerentes. A aplicação desse critério permitiu distinguir conjuntos com diferentes níveis de repetibilidade e evidenciou a influência das condições de medição sobre a variabilidade observada, em conformidade com os princípios de avaliação de incerteza do tipo A e B (Instituto Nacional de Metrologia, Qualidade e Tecnologia, 2012; Taylor, 1997).

Do ponto de vista pedagógico, esse achado é particularmente relevante, pois torna explícita a distinção entre variabilidade experimental controlável e variabilidade inerente ao sistema estudado. Ao vivenciar concretamente o impacto de erros aleatórios e sistemáticos sobre a confiabilidade dos resultados, os estudantes deslocaram o foco de uma abordagem algorítmica para uma compreensão conceitual da metrologia como prática científica, em consonância com a literatura que destaca o papel formativo do experimento na construção do conhecimento científico.

A identificação espontânea de fontes de erro relacionadas à marcação de pontos, alinhamento do eixo vertical e perspectiva das imagens reforça essa mudança conceitual. O erro experimental passou a ser compreendido como elemento intrínseco ao processo de medição, e não como falha individual, corroborando discussões recorrentes no ensino de Química Analítica sobre as dificuldades dos estudantes em atribuir significado físico a parâmetros estatísticos quando estes são ensinados de forma descontextualizada (Lehrer & Schauble, 2004).

Regressão linear como ferramenta interpretativa

A elevada qualidade dos ajustes lineares obtidos pela maioria dos grupos, expressa pelos altos valores de R^2 , indica domínio operacional da regressão linear como ferramenta de modelagem. Entretanto, mais relevante do que o desempenho numérico foi a apropriação conceitual do modelo, evidenciada na interpretação dos parâmetros e na discussão de seus limites.

Os estudantes demonstraram compreender o coeficiente angular como uma taxa média de crescimento anual, articulando o parâmetro matemático a um significado físico observável. Em contraste, dificuldades recorrentes na interpretação do intercepto linear foram identificadas, aspecto amplamente descrito na literatura e que reforça a necessidade de discutir explicitamente os pressupostos e limitações epistemológicas dos modelos matemáticos aplicados a fenômenos reais (Lehrer & Schauble, 2004; Skoog et al., 2007).

A comparação entre os Métodos A (regressão linear) e B (crescimento anual médio) ampliou essa compreensão ao evidenciar que diferentes modelos, ainda que matematicamente válidos, incorporam pressupostos distintos e podem conduzir a estimativas divergentes. Essa leitura comparativa está alinhada a abordagens de ensino baseadas em modelagem, nas quais o foco recai não apenas sobre a aplicação do modelo, mas sobre a análise crítica de sua adequação e alcance (Gilbert & Justi, 2016). A maior concordância entre os métodos nos grupos com melhor controle metrológico reforça a relação direta entre qualidade da medição e robustez da modelagem estatística.

Inteligência artificial como mediação cognitiva: potencialidades e limites

A integração de ferramentas de inteligência artificial mostrou-se mais produtiva quando utilizada como instrumento de validação, verificação de coerência e apoio reflexivo. Nesses casos, a IA atuou como mediadora cognitiva, favorecendo processos metacognitivos, revisão de procedimentos e explicitação de raciocínios, em consonância com abordagens que defendem a IA como apoio ao pensamento científico e à aprendizagem autorregulada (Holmes et al., 2019).

Ao confrontar seus próprios cálculos e interpretações com as respostas geradas pela IA, os estudantes foram levados a identificar inconsistências, revisar etapas e justificar escolhas metodológicas, ampliando a compreensão do tratamento de dados. Esse uso crítico dialoga diretamente com estudos recentes que discutem as potencialidades e os riscos do uso de modelos de linguagem generativa no contexto educacional, destacando que ganhos conceituais dependem fortemente da mediação pedagógica e do desenho da atividade (Kasneci et al., 2023).

Por outro lado, também foram observados usos mais superficiais da IA, restritos à confirmação de valores numéricos, sem aprofundamento conceitual. Esse achado reforça que o potencial educativo da IA não é intrínseco à tecnologia, mas condicionado à forma como é integrada ao processo de ensino-aprendizagem. A ausência de mediação tende a reforçar práticas instrumentais e riscos de dependência, limitando os benefícios formativos.

Evidências de aprendizagem significativa

À luz da teoria da Aprendizagem Significativa (Ausubel, 1968; Moreira, 2011), os dados quantitativos e qualitativos indicam evidências consistentes de ancoragem conceitual. Os estudantes mobilizaram conhecimentos prévios relacionados à proporcionalidade, conversão de unidades e representação gráfica, integrando-os a novos conceitos de metrologia, calibração interna, erro experimental e regressão linear.

As produções escritas revelaram explicações próprias, justificativas conceituais e reconhecimento explícito das limitações dos modelos empregados, ultrapassando a simples execução de procedimentos. A capacidade de relacionar resultados numéricos a pressupostos metodológicos, fontes de erro e escolhas de modelagem constitui indicativo de aprendizagem não mecânica, com potencial de transferência para outras situações analíticas.

O uso de um contexto realista e acessível, crescimento humano analisado por imagens digitais, contribuiu para atribuir significado ao tratamento de dados, favorecendo a compreensão conceitual e a atribuição de significado aos dados. Esse aspecto é particularmente relevante em contextos institucionais com restrições de infraestrutura, nos quais a experimentação tradicional é limitada, mas a análise de dados pode assumir papel formativo central.

Implicações para o ensino de Química Analítica em contextos com poucos recursos

Os achados deste estudo têm implicações diretas para o ensino de Química Analítica em instituições públicas brasileiras. A atividade proposta mostrou-se viável, de baixo custo, replicável e capaz de integrar conceitos centrais da disciplina, mesmo na ausência de equipamentos laboratoriais analíticos.

Ao substituir instrumentos físicos por imagens digitais e análise computacional, a proposta não empobrece o ensino experimental, mas desloca o foco para aspectos frequentemente negligenciados, como qualidade da medição, análise crítica de dados, interpretação de modelos e tomada de decisão baseada em evidências. Essa abordagem amplia a concepção de experimentação em Química Analítica, alinhando-a às demandas contemporâneas de formação científica e ao uso responsável de tecnologias digitais.

Limitações do estudo e perspectivas futuras

Entre as limitações do estudo destacam-se o número restrito de grupos, o uso de imagens bidimensionais e a adoção de modelos lineares simplificados para um fenômeno biologicamente complexo. Além disso, o uso da inteligência artificial não foi padronizado entre os grupos, o que limita análises comparativas mais sistemáticas sobre seu impacto específico.

Essas limitações, contudo, são coerentes com o caráter pedagógico e exploratório da proposta e foram incorporadas como oportunidades formativas. Estudos futuros podem expandir a abordagem para outras grandezas analíticas, incorporar tratamentos de incerteza mais formais, comparar diferentes estratégias de mediação com IA e investigar efeitos de longo prazo na aprendizagem.

Conclusão

Este estudo indicou que a integração entre experimentação digital, princípios de metrologia e uso orientado de ferramentas de inteligência artificial constitui uma alternativa didaticamente consistente e tecnicamente defensável para o ensino de Química Analítica em contextos com limitações de infraestrutura laboratorial. A atividade proposta permitiu aos estudantes vivenciar etapas centrais da análise química (medição, calibração, controle de erro, modelagem estatística e interpretação de dados) por meio de um experimento acessível, de baixo custo e replicável.

Os resultados quantitativos mostraram que a explicitação de critérios metrológicos de qualidade, como o erro relativo percentual, permitiu distinguir medições com diferentes níveis de repetibilidade e discutir a variabilidade associada às

medições digitais. Esse controle metrológico forneceu base para a análise da consistência numérica dos resultados e para a discussão conceitual da confiabilidade dos dados, aspecto central da formação em Química Analítica.

Do ponto de vista pedagógico, a atividade contribuiu para deslocar o foco do ensino de uma abordagem predominantemente algorítmica para uma compreensão mais crítica e reflexiva do tratamento de dados experimentais. As evidências qualitativas indicaram que os estudantes reconheceram o erro experimental como componente intrínseco ao processo de medição, interpretaram parâmetros estatísticos à luz de seus significados físicos e discutiram limites e pressupostos dos modelos matemáticos empregados.

A utilização da inteligência artificial, quando mediada de forma explícita pela docente, atuou como ferramenta de apoio à validação de cálculos, à checagem de coerência estatística e à reflexão metacognitiva, sem substituir o raciocínio científico dos estudantes. Esses achados reforçam que o potencial educativo da IA não reside em sua automação, mas em seu uso crítico e orientado, integrado a objetivos pedagógicos bem definidos.

Embora o estudo apresente limitações inerentes ao seu caráter exploratório e ao contexto educacional específico, os resultados obtidos indicam que propostas baseadas em experimentação digital e análise de dados podem ampliar significativamente as possibilidades de ensino de Química Analítica em instituições públicas. Ao valorizar a metrologia, a interpretação crítica de resultados e a tomada de decisão fundamentada em evidências, a atividade contribui para uma formação analítica alinhada às demandas contemporâneas do ensino de Ciências.

Conclui-se, portanto, que a abordagem apresentada constitui uma estratégia pedagógica viável e relevante para o ensino de Química Analítica, especialmente em cenários nos quais a ausência de equipamentos laboratoriais tradicionais impõe desafios adicionais, mas também abre espaço para inovação didática fundamentada em princípios científicos sólidos.

Referências

- Ausubel, D. P. (1968). *Educational psychology: A cognitive view*. Holt, Rinehart and Winston.
- Galiazzi, M. C., & Gonçalves, F. P. (2004). A natureza pedagógica da experimentação: Uma pesquisa na licenciatura em Química. *Química Nova*, 27(2), 326–331.
<https://doi.org/10.1590/S0100-40422004000200027>
- Gilbert, J. K., & Justi, R. (2016). *Modelling-based teaching in science education*. Springer.
<https://doi.org/10.1007/978-3-319-29039-3>
- Guo, Y., & Lee, D. (2023). Leveraging ChatGPT for enhancing critical thinking skills. *Journal of Chemical Education*, 100(12), 4876–4883.
<https://doi.org/10.1021/acs.jchemed.3c00505>
- Harris, D. C. (2007). *Quantitative chemical analysis* (7th ed.). W. H. Freeman.
- Hodson, D. (1993). Re-thinking old ways: Towards a more critical approach to practical work in school science. *Studies in Science Education*, 22(1), 85–142.
<https://doi.org/10.1080/03057269308560022>
- Holmes, W., Bialik, M., & Fadel, C. (2019). *Artificial intelligence in education: Promises and implications for teaching and learning*. Center for Curriculum Redesign.
- Instituto Nacional de Metrologia, Qualidade e Tecnologia. (2012). *Avaliação de dados de medição: Guia para a expressão de incerteza de medição (GUM)*. INMETRO.
- Iyamuremye, A. (2024). Utilization of artificial intelligence and machine learning in chemistry education: A systematic review. *Discover Education*, 3(1), Article 98.
<https://doi.org/10.1007/s44217-024-00098-w>
- Jarujareet, U., Udnan, Y., & Jakmunee, J. (2023). A low-cost dual-beam smartphone visible spectrometer for determination of phosphate in water samples. *Journal of Chemical Education*, 100(4), 1600–1607.
<https://doi.org/10.1021/acs.jchemed.2c00642>
- Kasneci, E., Sessler, K., Küchemann, S., Bannert, M., Dementieva, D., Fischer, F., Gasser, U., Groh, G., Günnemann, S., Hüllermeier, E., Krusche, S., Kutyniok, G., Michaels, J., Nerdel, C., Pfeffer, J., Poquet, O., Sailer, M., Schmidt, A., Seidel, T., & Kasneci, G. (2023). ChatGPT for good? On opportunities and challenges of large language

- models for education. *Learning and Individual Differences*, 103, Article 102274.
<https://doi.org/10.1016/j.lindif.2023.102274>
- Krasilchik, M. (2008). *Prática de ensino de biologia* (4^a ed.). Edusp.
- Lehrer, R., & Schauble, L. (2004). Modeling natural variation through distribution. *American Educational Research Journal*, 41(3), 635–679.
<https://doi.org/10.3102/00028312041003635>
- Moreira, M. A. (2011). *Aprendizagem significativa: A teoria e textos complementares*. Livraria da Física.
- National Center for Health Statistics. (2002). *2000 CDC growth charts for the United States: Methods and development* (Vital and Health Statistics, Series 11, No. 246).
<https://stacks.cdc.gov/view/cdc/6451>
- Pence, H. E., Hightower, G., Forlenza, J., Leonard, K., McLellan, A., Suero, A., Amoah, B., Mbow, M., Borner, S., Castillo, A., & Pence, L. E. (2024). Using generative AI systems for critical thinking engagement in an advanced chemistry course: A case study. *Journal of Chemical Education*, 101(9), 3789–3794.
<https://doi.org/10.1021/acs.jchemed.4c00242>
- Santos, C. J. S. dos. (2022). *Experimentos de baixo custo para o ensino de química por abordagem significativa e por investigação para alunos da 2^a série do ensino médio* [Trabalho de conclusão de curso, Universidade Federal de Alagoas]. Repositório Institucional da UFAL.
<https://www.repositorio.ufal.br/handle/123456789/8915>
- Schnetzler, R. P. (2002). A pesquisa em ensino de Química no Brasil: Conquistas e perspectivas. *Química Nova*, 25(Suppl. 1), 14–24.
<https://doi.org/10.1590/S0100-40422002000800004>
- Skoog, D. A., Holler, F. J., & Crouch, S. R. (2007). *Principles of instrumental analysis* (6th ed.). Thomson Brooks/Cole.
- Tassoti, S. (2024). Assessment of students use of generative artificial intelligence: Prompting strategies and prompt engineering in chemistry education. *Journal of Chemical Education*, 101(6), 2475–2482.
<https://doi.org/10.1021/acs.jchemed.4c00212>
-

Taylor, J. R. (1997). *An introduction to error analysis: The study of uncertainties in physical measurements* (2nd ed.). University Science Books.

World Health Organization. (2007). *Growth reference data for 5–19 years: Height-for-age (5–19 years)*.

<https://www.who.int/tools/growth-reference-data-for-5to19-years/indicators/height-for-age>

Submetido em: 21/12/2025

Aceito em: 22/08/2026

Publicado em: 09/10/2026

Periódico organizado pela Sociedade Brasileira de Ensino de Química – SBEnQ



Este texto é licenciado pela Creative Commons Attribution 4.0 International License.