



MINISTÉRIO DA EDUCAÇÃO
Universidade Federal de Ouro Preto
Instituto de Ciências Exatas e Aplicadas
Especialização em Ciência de Dados



**Previsão da conformabilidade global de aços destinados ao
setor automotivo por meio de ensaios de tração: Uma
abordagem por aprendizado de máquina**

Felipe Pereira Finamor

João Monlevade, MG
2022

Felipe Pereira Finamor

**Previsão da conformabilidade global de aços destinados ao
setor automotivo por meio de ensaios de tração: Uma
abordagem por aprendizado de máquina**

Trabalho de conclusão de curso apresentado ao curso de Ciência de Dados do Instituto de Ciências Exatas e Aplicadas da Universidade Federal de Ouro Preto, como parte dos requisitos necessários para a obtenção do título de Especialista em Ciência de Dados.

Orientador: Prof. Dr. Harlei Miguel de Arruda Leite

João Monlevade, MG

2022

SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

F491p Finamor, Felipe Pereira.

Previsão da conformabilidade global de aços destinados ao setor automotivo por meio de tração [manuscrito]: uma abordagem por aprendizado de máquina. / Felipe Pereira Finamor. - 2022.

44 f.: il.: color., gráf., tab..

Orientador: Prof. Dr. Harlei Miguel de Arruda Leite.
Produção Científica (Especialização). Universidade Federal de Ouro Preto. Departamento de Engenharia de Produção.

1. Aprendizado de Máquina. 2. Conformação de metais - Curva Limite de Conformação. 3. Conformabilidade. I. Leite, Harlei Miguel de Arruda. II. Universidade Federal de Ouro Preto. III. Título.

CDU 621.98:004.85

Bibliotecário(a) Responsável: Sione Galvão Rodrigues - CRB6 / 2526



FOLHA DE APROVAÇÃO

Felipe Pereira Finamor

Previsão da conformabilidade global de aços destinados ao setor automotivo por meio de tração: uma abordagem por aprendizado de máquina

Monografia apresentada ao Curso de especialização em Ciências de Dados da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de Especialista em Ciência de Dados

Aprovada em 04 de novembro de 2022

Membros da banca

Prof. Dr. Harlei Miguel de Arruda Leite - Orientador (Universidade Federal de Ouro Preto)

Me. Guilherme Vettorazzi Vargas - (Universidade Estadual de Campinas)

Profa. Dra. Sarah Negreiros de Carvalho Leite - (Universidade Federal de Ouro Preto)

Prof. Dr. Harlei Miguel de Arruda Leite, orientador do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 10/07/2023



Documento assinado eletronicamente por **Harlei Miguel de Arruda Leite, PROFESSOR DE MAGISTERIO SUPERIOR**, em 10/07/2023, às 21:05, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **0555983** e o código CRC **5ED3C578**.

Aos amores da minha vida: Cibele e Sofia!

Agradecimentos

Agradeço a todos que, direta ou indiretamente, contribuíram para que este trabalho fosse concluído e, de uma forma especial:

À USIMINAS, por meio da Gerência Geral de Pesquisa e Desenvolvimento e aos gerentes Aldo Henrique de Almeida Barbosa e Carlos Salaroli de Araújo pela confiança, incentivo e apoio para a realização deste trabalho;

Aos colegas de trabalho Marco Antônio Wolff, Francislayne Lages Dias, Robson Andrade Vieira, Valdilei Santana Lage, Heitor Cezar da Silva, Tairine Berbert Tavares, Júlio Cezar de Souza Zorzi e Tadeu Messias Donizete Borba, pelas ideias, sugestões e dedicação para que este trabalho se realizasse;

À UFOP e seus professores, pela oportunidade de voltar a ser seu aluno, além de nos proporcionar um curso de elevada qualidade;

Aos colegas de estudo, em especial ao Kleber Macedo e Priscila Batista, pelas trocas de experiência e pelas noites de estudo.

“The man in black fled across the desert, and the gunslinger followed.”
Stephen King - Gunslinger - The Dark Tower

Resumo

As Curvas Limite de Conformação (CLCs) são amplamente empregadas pela indústria automotiva para a verificação das deformações limites nos processos que envolvem conformação mecânica de chapas finas, como é o caso da estampagem. Sendo a CLC um instrumento aliado à redução de custos, avaliação das ferramentas de estampagem e seleção de materiais. Entretanto, seu levantamento experimental é um processo que demanda tempo, recursos laboratoriais específicos e é limitado à disponibilidade de amostras relativamente grandes. Estudar a correlação e a previsão das CLCs à estricção e as propriedades mecânicas em tração surge como uma alternativa à estas limitações. Nesse caso, diversos modelos teóricos clássicos foram criados, como o de Keeler-Brazier (KB) e Marciniak-Kuczynski (MK). Entretanto, esses modelos são limitados à alguns materiais e, se comparados aos dados reais, possuem erros relativamente grandes. Visando determinar a conformabilidade dos aços destinados ao setor automotivo, por meio da previsão da curva limite de conformação e sua relação com diferentes propriedades mecânicas, modelos de aprendizado de máquina, juntamente com ensaios laboratoriais de tração e de curva limite de conformação foram empregados. Os resultados de previsão foram comparados com dados experimentais, cujos resultados de previsão se mostraram promissores, com erro relativo médio total entre os resultados experimentais e aqueles previstos pelo modelo final de 7%. Esse erro pode ser considerado baixo, haja vista que as CLCs são usualmente empregadas com margens de segurança da ordem de 10 a 20%. Ademais, o uso de técnicas de inteligência artificial explicável (*eXplainable Artificial Intelligence* ou XAI) mostraram as variáveis que mais afetaram a previsão da conformabilidade, apresentando um caminho para a otimização e melhoria dos aços avaliados.

Palavras-chaves: Conformabilidade. Curva Limite de Conformação. Aprendizado de Máquina.

Abstract

The Forming Limit Curves (FLCs) are widely used by the automotive industry in order to assess the limit strains in processes that involves sheet metal forming. FLCs are usually associated with cost reduction, evaluation of forming dies and material selection. However, its experimental process demands time, specific resources and is limited to the availability of large samples. Studying the correlation and prediction of FLCs at necking and tensile mechanical properties appears as an alternative to these limitations. In this case, several classical theoretical models were created, such as the Keeler-Brazier (KB) and Marciniak-Kuczynski (MK) models. However, these models are limited to some materials and, compared to real data, have relatively large errors. Aiming to determine the formability of steels destined for the automotive sector, through the prediction of the forming limit curve and its relationship with different mechanical properties, machine learning models, together with laboratory tensile tests and forming limit curves were used. The prediction results were compared with experimental data. The prediction results shows a promising use, with a total mean relative error between the experimental tests and those predicted by the final model of about 7%. This error can be considered at low magnitude, given that FLCs are usually used with safety margins in the order of 10 to 20%. Furthermore, the use of eXplainable Artificial Intelligence (XAI) showed the most important features that most affected the formability prediction, presenting a path for the optimization and improvement of the evaluated steels.

Keywords: formability. forming limit curve. machine learning.

Lista de ilustrações

Figura 1 – Curva Limite de Conformação mostrando os diferentes corpos de prova utilizados para sua obtenção.	4
Figura 2 – Efeito do coeficiente de anisotropia normal sobre a trajetória de deformação.	5
Figura 3 – Influência do expoente de encruamento sobre a CLC.	6
Figura 4 – Influência do coeficiente de encruamento e da espessura sobre a CLC_0	7
Figura 5 – Efeito do limite de resistência e alongamento total na CLC_0 de aços empregados no setor automotivo.	8
Figura 6 – Simulação numérica de estampagem com os pontos de deformação e a Curva Limite de Conformação (CLC) em peça estampada a partir de aço DP780.	9
Figura 7 – Ciclo de desenvolvimento do modelo <i>Cross Industry Standard Process for Data Mining</i> (CRISP DM).	12
Figura 8 – Diagrama esquemático de uma DT.	14
Figura 9 – Arquitetura básica de uma ANN.	15
Figura 10 – Propriedades mecânicas distribuídas ao longo do banco de dados.	22
Figura 11 – Distribuição dos valores de ε_1 e ε_2 ao longo do banco de dados, para diferentes trajetórias de deformação.	23
Figura 12 – Distribuição dos valores de espessura (mm) ao longo do banco de dados.	24
Figura 13 – Heatmap mostrando a intensidade dos coeficientes de relação linear de Pearson.	25
Figura 14 – Estatística descritiva das variáveis utilizadas.	25
Figura 15 – Distribuição dos valores de ε_1 ao longo das trajetórias de deformação por embutimento, CLC_0 e estiramento.	26
Figura 16 – Distribuição dos valores de ε_1 ao longo das trajetórias de deformação por embutimento, CLC_0 e estiramento, considerando os agrupamentos formados por k-means.	28
Figura 17 – Screeplot - Variância explicada em função do número de componentes principais.	29
Figura 18 – Biplot das componentes principais Componente Principal 1 (PC1) e Componente Principal 2 (PC2) e sua relação com as propriedades mecânicas em tração.	30
Figura 19 – Valores dos desempenhos dos algoritmos para ε_1 , considerando a trajetória de deformação por embutimento.	32
Figura 20 – Valores dos desempenhos dos algoritmos para ε_1 , considerando a trajetória de deformação por deformação plana (CLC_0).	33
Figura 21 – Valores dos desempenhos dos algoritmos para ε_1 , considerando a trajetória de deformação por estiramento.	34

Figura 22 – Gráfico de dispersão entre os valores reais e previstos para a base de teste, considerando os valores de ϵ_1 para os modos de deformação por embutimento, deformação plana (CLC_0) e estiramento.	35
Figura 23 – Valores previstos e reais das CLCs, considerando a incerteza de medição (IM) e o intervalo de previsão (IP) para os aços DP780 e TRIP780.	38
Figura 24 – Valores de Shapley obtidos para a trajetória de deformação de embutimento, a partir do pacote SHAP (LUNDBERG <i>et al.</i> , 2020), considerando o modelo XGB.	39
Figura 25 – Valores de Shapley obtidos para a trajetória de deformação plana (CLC_0), a partir do pacote SHAP (LUNDBERG <i>et al.</i> , 2020), considerando o modelo XGB.	39
Figura 26 – Valores de Shapley obtidos para a trajetória de deformação de estiramento, a partir do pacote SHAP (LUNDBERG <i>et al.</i> , 2020), considerando o modelo SVM.	39

Lista de tabelas

Tabela 1 – Tabela de aços empregados no desenvolvimento do banco de dados de tração e CLCs.	18
Tabela 2 – Hiperparâmetros obtidos para os melhores modelos.	36
Tabela 3 – Valores da incerteza expandida (U_{exp}) e do intervalo de previsão para o modelo final, para cada trajetória de deformação.	36

Lista de abreviaturas e siglas

AHSS *Advanced High Strength Steels*

ANN Redes Neurais Artificiais

CLC Curva Limite de Conformação

CRISP DM *Cross Industry Standard Process for Data Mining*

DT *Decision Trees*

HSLA *High Strength Low Alloy*

I.C. Intervalo de Confiança da Previsão

I.M. Incerteza de Medição

IA Inteligência Artificial

IF *Interstitial Free*

KNN *K-Nearest Neighbors*

MAE *Mean Absolute Error*

MAPE *Mean Absolute Percentage Error*

ML *Machine Learning*

PC1 Componente Principal 1

PC2 Componente Principal 2

PCA Análise de Componentes Principais

RMSE *Root Mean Squared Error*

XAI *eXplainable Artificial Intelligence*

Lista de símbolos

AL_T	Alongamento Total
ϵ_u	Alongamento Uniforme
CLC_0	Valor de ϵ_1 , quando ϵ_2 é igual a zero
ϵ_1	Maior deformação verdadeira
ϵ_2	Menor deformação verdadeira
LE	Limite de Escoamento
LR	Limite de Resistência
n	Expoente de encruamento
\bar{r}	Coefficiente de anisotropia normal
R^2	Coefficiente de determinação
u_{eq}	Incerteza de medição da máquina de ensaio
U_{exp}	Incerteza expandida
u_{res}	Incerteza da resolução do equipamento

Sumário

1	INTRODUÇÃO	1
1.1	Objetivo geral	2
1.1.1	Objetivos específicos	2
1.2	Contribuições	2
1.3	Organização do Trabalho	2
2	REVISÃO DA LITERATURA	3
2.1	Conformabilidade	3
2.2	Curva limite de conformação (CLC)	4
2.3	Fatores que afetam a curva limite de conformação	4
2.3.1	Coefficiente de anisotropia normal	5
2.3.2	Expoente de encruamento	6
2.3.3	Espessura da chapa	6
2.3.4	Alongamento uniforme	7
2.3.5	Limite de resistência e alongamento total	7
2.4	Dispersão estatística da conformabilidade	7
2.5	Uso da CLC para simulação numérica dos processos de estampagem	9
2.6	Incertezas de medição	9
2.7	Aprendizado de máquina	10
2.8	Mineração de dados e extração de conhecimento	11
2.8.1	Entendimento do negócio	11
2.8.2	Compreensão dos dados	12
2.8.3	Preparação dos dados	12
2.8.4	Modelagem	13
2.8.5	Avaliação	13
2.8.6	Implantação	13
2.9	Modelos de machine learning	13
2.9.1	Árvores de decisão (DT)	13
2.9.2	XGBoost - eXtreme Gradient Boosting	14
2.9.3	K vizinhos próximos (KNN)	14
2.9.4	Redes Neurais Artificiais (ANN)	15
2.9.5	MARS	15
2.9.6	GLMNET	16
2.9.7	CUBIST	16
2.9.8	RANSAC	16

2.10	Métodos de avaliação dos modelos	16
3	METODOLOGIA	18
3.1	Construção da base de dados	18
3.2	Normalização do banco de dados	19
3.3	Modelamento	19
3.4	Divisão do banco de dados	19
3.5	Desempenho da previsão	20
3.6	Previsão das curvas limite de conformação	20
3.7	Incerteza de medição da CLC experimental	20
4	RESULTADOS	21
4.1	Construção da base de dados	21
4.2	Exploração da base de dados	21
4.3	Análise de agrupamentos	27
4.4	Análise de componentes principais	29
4.5	Divisão da base de dados	30
4.6	Resultados de previsão	31
4.7	Incerteza de medição e intervalo de confiança da previsão	36
4.8	Previsão da base de teste	37
4.9	Explicação do modelo final	37
5	CONSIDERAÇÕES FINAIS	40
	REFERÊNCIAS	41

1 Introdução

O setor siderúrgico vem adotando investimentos cada vez maiores na busca pela melhoria da qualidade de seus produtos, em especial na garantia da uniformidade de propriedades mecânicas ao longo da bobina e entre diferentes lotes de produção. Entretanto, alcançar tal uniformidade é um trabalho complexo, que depende de uma série de fatores distribuídos ao longo das etapas de produção do aço, como disponibilidade e tipo de matéria prima, estabilidade operacional, investimentos, chances de produção, dentre outros (COLLA *et al.*, 2020; BERG *et al.*, 2018).

Pode-se afirmar que os produtos siderúrgicos possuem algum grau de variabilidade em suas propriedades mecânicas, o que impacta outras características associadas à sua aplicação, em especial sua conformabilidade ou capacidade de se deformar sobre esforços mecânicos. Uma das principais formas de se avaliar a conformabilidade dos aços é pelo emprego da Curva Limite de Conformação (CLC) (KEELER; KIMCHI, 2017). A obtenção experimental das CLCs é um processo que demanda tempo, recursos laboratoriais específicos e é limitado à disponibilidade de amostras relativamente grandes.

De acordo com Paul (2021), Abbasi *et al.* (2012) e Keeler e Kimchi (2017), o estudo da correlação entre a CLC à estrição e as propriedades mecânicas em tração, principalmente de *Advanced High Strength Steels* (AHSS), é uma área em constante desenvolvimento, onde se observam inúmeros trabalhos relacionados aos modelos teóricos clássicos de Keeler-Brazier (KB) e Marciniak-Kuczynski (MK), bem como os novos métodos de previsão, empregando modelos de dano acumulado e de *crystal plasticity*. Contudo, esses modelos dependem de um extensivo número de ensaios e calibrações de ajuste para aplicação, além de possuírem erros relativamente grandes com os valores experimentais. Uma alternativa que vem se tornando viável com o aprimoramento da capacidade de processamento dos novos sistemas computacionais é o uso de algoritmos de *Machine Learning* (ML), ou algoritmos de aprendizado de máquina, para a previsão das propriedades dos materiais, considerando suas diversas aplicações (CHHEDA *et al.*, 2019; FINAMOR; WOLFF; LAGE, 2021).

Visando prever a curva limite de conformação e sua relação com diferentes propriedades mecânicas, modelos de aprendizado de máquina, juntamente com ensaios laboratoriais de tração e de curva limite de conformação foram empregados. Os resultados de previsão foram comparados com dados experimentais, não participantes do treinamento e validação do modelo e se mostraram promissores com valor de erro de previsão próximo aos valores de incerteza de medição do ensaio.

1.1 Objetivo geral

Desenvolver um modelo capaz de prever a curva limite de conformação de aços destinados ao setor automotivo, a partir de dados de propriedades mecânicas em tração obtidas industrialmente.

1.1.1 Objetivos específicos

- Construir um banco de dados contendo informações sobre propriedades mecânicas em tração e curvas limite de conformação;
- Treinar e validar diferentes modelos de regressão;
- Avaliar o efeito das variáveis na previsão da [CLC](#).

1.2 Contribuições

Esse trabalho contribuiu para o desenvolvimento de novos métodos de previsão da curva limite de conformação, estendendo a compreensão dos fatores de influência sobre a curva. Ademais, foi publicado o artigo no 40th International Deep-Drawing Research Group Conference (IDDRG 2021) sob o título:

Prediction of forming limit diagrams from tensile tests of automotive grade steels by a machine learning approach ([FINAMOR; WOLFF; LAGE, 2021](#)).

1.3 Organização do Trabalho

No Capítulo 1 é apresentada uma breve contextualização do problema a ser resolvido e os objetivos do trabalho. No Capítulo 2 os principais trabalhos sobre o tema são abordados e o Capítulo 3 estabelece os métodos propostos, bem como as configurações do banco de dados a serem usados. O Capítulo 4 sintetiza e avalia os resultados alcançados. Por fim, o Capítulo 5 conclui o trabalho, apresentando as principais contribuições e as propostas de trabalhos futuros.

2 Revisão da Literatura

2.1 Conformabilidade

Entende-se como conformabilidade (BANABIC, 2010; HOSFORD; CADDELL, 2011; LIMBADRI *et al.*, 2015) ou, estampabilidade, a capacidade do material em se deformar plasticamente sem que ocorram trincas, fraturas ou afinamento excessivo. Segundo Hosford e Caddell (2011) e Banabic (2010), a conformabilidade é uma característica complexa, na qual influem diferentes variáveis, dependendo tanto das propriedades do material (propriedades mecânicas, metalúrgicas e químicas), quanto das condições de deformação impostas pelo processo de conformação durante sua aplicação.

A conformabilidade é uma propriedade importante nas operações de estampagem, podendo ser decomposta em conformabilidade global e local, a depender das condições e restrições das deformações ao longo da peça (HANCE, 2016; CHEONG; BUTCHER; DYKEMAN, 2018; KEELER; KIMCHI, 2017).

A conformabilidade global descreve a habilidade do material em suportar as deformações que ocorrem ao longo de grandes regiões, sendo associada aos modos de deformação por embutimento, estiramento e deformação plana. Essa propriedade pode ser estimada por meio da Curva Limite de Conformação (CLC) e pelos resultados obtidos a partir de ensaios de tração, como o expoente de encruamento, anisotropia normal e alongamentos uniforme e total (HANCE, 2016; CHEONG; BUTCHER; DYKEMAN, 2018; KEELER; KIMCHI, 2017).

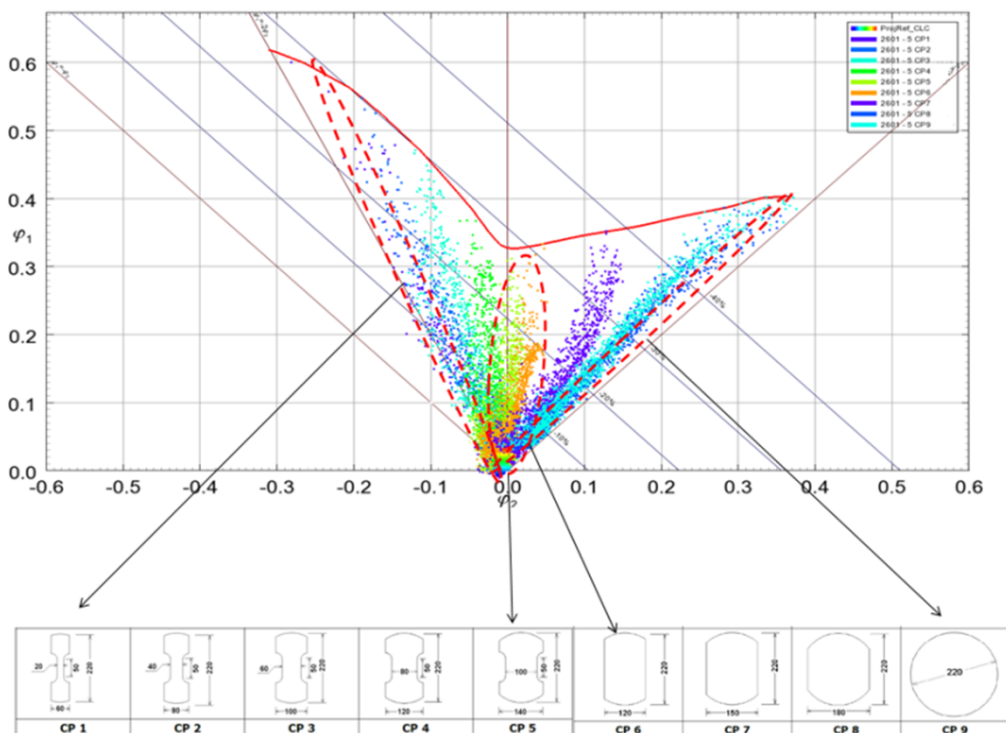
A conformabilidade local, por sua vez, é medida como a resistência à fratura em locais onde as deformações são concentradas (por isso o termo local), associada à deformação ao longo da espessura, como nos casos de estiramento de flange, expansão de furo, dobramento sob estiramento e dobramento em raios extremamente críticos. Essa característica está relacionada com as condições da qualidade das bordas e com a homogeneidade microestrutural (HANCE, 2016; CHEONG; BUTCHER; DYKEMAN, 2018; KEELER; KIMCHI, 2017; WESTHÄUSER; SCHNEIDER; DENKS, 2017).

Apesar de serem propriedades essenciais para o sucesso da aplicação do material, deve-se salientar que a caracterização da conformabilidade é limitada. Isso se deve principalmente ao efeito de escala e à complexidade do estado de tensões e deformações impostas na peça durante a etapa de produção industrial, se comparada às amostras utilizadas durante os ensaios laboratoriais (WESTHÄUSER; SCHNEIDER; DENKS, 2017).

2.2 Curva limite de conformação (CLC)

Na Figura 1 é representada a **CLC**, obtida pelo mapeamento das deformações limites provenientes da conformação de um aço por ação de um punção (BANABIC, 2010). É possível obter modos de deformação distintos por meio do emprego de corpos de prova com geometrias diferentes, como embutimento, estado plano de deformação e estiramento biaxial. Seu emprego mais comum é o de servir como critério de falha para os softwares de simulação numérica de estampagem, definindo as deformações limites que a peça pode suportar além de ser empregada na análise e seleção de materiais (BANABIC, 2010; PAUL, 2021).

Figura 1 – Curva Limite de Conformação mostrando os diferentes corpos de prova utilizados para sua obtenção.



Fonte: Próprio autor.

2.3 Fatores que afetam a curva limite de conformação

Considerando que a curva limite de conformação é a principal ferramenta empregada para prever o comportamento do aço durante a estampagem, a indústria siderúrgica deve se preparar para providenciar os dados que permitam o uso correto da **CLC**, bem como fornecer materiais que consigam aliar as melhores características de conformação para determinada aplicação.


Como uma característica do aço, a CLC é afetada pelas variações do processo produtivo, entretanto, o estudo de quais fatores industriais são atrelados às variações da posição da CLC não é uma atividade trivial (PAUL, 2021). Neste caso, por exemplo, não foram encontrados relatos na literatura que tratem dos efeitos dos parâmetros produtivos no incremento da conformabilidade dos aços. Outrossim, encontram-se relatos dos efeitos da microestrutura e dos efeitos das propriedades mecânicas na posição e formato da curva, que são uma resposta do processo produtivo (PAUL, 2021). Nesse sentido, vários fatores que contribuem para as variações nas propriedades mecânicas também agem na modificação da conformabilidade dos aços, relacionando-se com a composição química e a rota de processamento do material (BANABIC, 2010).

Discute-se a seguir o efeito de alguns dos parâmetros obtidos no ensaio de tração uniaxial no formato e posição da CLC.

2.3.1 Coeficiente de anisotropia normal

O efeito do coeficiente de anisotropia normal \bar{r} , calculado no ensaio de tração, é mostrado na Figura 2. Pode-se observar que o aumento do valor de \bar{r} incrementa as deformações limites, especialmente na região de menores deformações negativas ($\epsilon_2 < 0$) (TISZA; KOVÁCS, 2012). O aumento do valor de \bar{r} possibilita ao material admitir maiores deformações no plano do que na espessura da chapa, aumentando, assim, as deformações até a fratura (Usinas Siderúrgicas de Minas Gerais - Usiminas, 1984).

Figura 2 – Efeito do coeficiente de anisotropia normal sobre a trajetória de deformação.




Fonte: Tisza e Kovács (2012).

2.3.2 Expoente de encruamento

O valor do expoente de encruamento (n), de acordo com [Schwindt *et al.* \(2015\)](#), tem maior influência sobre o regime de estiramento do material, como visto na Figura 3. O modo de deformação por estiramento é o resultado do aumento da área do *blank* por meio de um estado biaxial de tração. Isto implica que, sendo as duas deformações no plano da chapa positivas e como a soma das três deformações principais é nula, a deformação na direção da espessura será obrigatoriamente negativa. Ou seja, haverá redução de espessura nesta região do *blank*. Então, a capacidade do material de absorver esta redução sem que ocorra instabilidade plástica, vai se expressar em diferenças na posição da CLC, já que o material com maiores expoentes de encruamento tem maior facilidade de distribuir essas deformações ([Usinas Siderúrgicas de Minas Gerais - Usiminas, 1984](#)).


Figura 3 – Influência do expoente de encruamento sobre a CLC.



Fonte: [Schwindt *et al.* \(2015\)](#).

2.3.3 Espessura da chapa

Apesar do uso de materiais de alta conformabilidade, uma das soluções mais fáceis de enfrentar dificuldades na estampagem é a utilização de chapas de maior espessura ([BANABIC, 2010](#)). Este aumento de espessura eleva as deformações necessárias para que ocorra a estricção do material, deslocando a CLC para maiores deformações. O valor de CLC_0 (Valor de ϵ_1 , quando ϵ_2 é igual a zero), referente ao menor ponto de ϵ_1 na curva, aumenta linearmente com o aumento da espessura, como mostrado na Figura 4. Contudo, de acordo com [Wenlong, Xiaokai e Lu \(2016\)](#), o aumento da espessura vai à contramão das propostas atuais de redução de peso, almejada pela indústria automotiva.

Figura 4 – Influência do coeficiente de encruamento e da espessura sobre a CLC_0 .

Fonte: Keeler e Kimchi (2017).

2.3.4 Alongamento uniforme

Outro fator de interesse é o alongamento uniforme, ϵ_u , extraído do ensaio de tração. Essa característica representa o quanto o material resiste à estrição localizada, a partir da qual há uma transição para a capacidade do material em suportar deformações localizadas ou *necking* (HICKEY, 2021). Maiores os valores de alongamento uniforme, maiores as deformações suportadas pelo material antes da estrição.

2.3.5 Limite de resistência e alongamento total

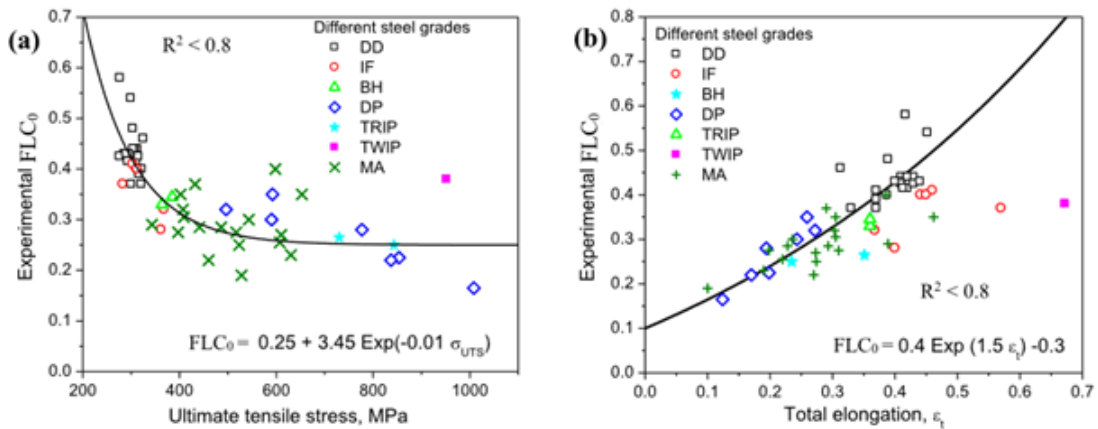
De acordo com Paul (2021), Figura 5, o limite de resistência tem influência até determinado nível, apresentando um decaimento exponencial da conformabilidade em razão do aumento da resistência do aço. Por sua vez, esse mesmo autor credita ao alongamento total um aumento da conformabilidade dos aços de modo exponencial. De maneira geral, maiores os valores de alongamento total, maiores os valores de CLC_0 dos aços avaliados.

2.4 Dispersão estatística da conformabilidade

Minh, Sowerby e Duncan (1974), ao avaliarem a conformabilidade de alguns aços baixo carbono, afirmam que: “a falha é um processo, por si só, probabilístico”.

Isso significa que a caracterização da conformabilidade de um material necessita do entendimento da ambiguidade, derivada da subjetividade do posicionamento da CLC , considerando a dispersão dos valores de deformação. Isto é, faz-se necessário o uso de métodos estatísticos para se compreender a característica randômica da falha em conformação mecânica.

Figura 5 – Efeito do limite de resistência e alongamento total na CLC_0 de aços empregados no setor automotivo.



Fonte: Paul (2021).

Janssens *et al.* (2001) propuseram um método de avaliação estatística baseado na dispersão dos resultados, criando uma faixa de construção para a CLC . O método consiste em, primeiramente, traçar uma curva CLC de referência nos pontos médios das deformações medidas durante o ensaio. A dispersão dos resultados é, então, caracterizada pela distância perpendicular de cada ponto médio à CLC . O desvio padrão dessa dispersão é usado para calcular o intervalo de confiança, compreendendo um intervalo de possibilidade de deformações limite para o material.

Segundo Janssens *et al.* (2001), este tipo de análise pode substituir a margem de segurança, que normalmente é traçada à uma distância de 5% a 20% abaixo da CLC , em conformidade com recomendações práticas e de fabricantes de software de simulação de estampagem.


Os dados fornecidos por Janssens *et al.* (2001) e Strano e Colosimo (2006) permitem inferir que a construção das $CLCs$ é consideravelmente mais sensível às variações das propriedades do material do que àquelas provocadas pelo método de medição das deformações. Isso significa que a CLC é uma característica única e exclusiva para um dado material, revestimento e rota de processamento e não deve ser tratada como uma região de separação entre deformações “seguras” e “não seguras”, mas sim como um critério de risco de possibilidade de falha.

2.5 Uso da CLC para simulação numérica dos processos de estampagem

Muitas empresas de estampagem possuem em seus departamentos de engenharia áreas dedicadas ao design, desenvolvimento e simulação de ferramentas e de processos de estampagem. Os riscos detectados durante a fase de simulação facilitam a mitigação de problemas que poderiam ocorrer na etapa de produção industrial da peça. Neste sentido, quanto melhores os modelos de materiais empregados, maiores as chances de a simulação numérica representar um processo de estampagem, minimizando, assim, os custos com *try-out* de ferramentas e índice de refugo de peças.

A Figura 6 apresenta uma simulação numérica de estampagem com o uso do *software* Autoform (TORSTENSSON, 2022), de peça produzida a partir do aço DP780. As deformações fornecidas pela simulação aparecem muito próximas à CLC, acenando à falha do componente durante a estampagem em função de quaisquer variações do processo de estampagem ou das propriedades do material.

Figura 6 – Simulação numérica de estampagem com os pontos de deformação e a CLC em peça estampada a partir de aço DP780.



Fonte: Próprio autor.

2.6 Incertezas de medição

O valor verdadeiro de um mensurando não é conhecido e qualquer resultado de uma medição será somente uma estimativa do mensurando em si. Assim, toda medição traz consigo uma dúvida, que pode ser traduzida como a incerteza de uma medição (ISO, 2004).

A incerteza de medição, por sua vez, pode ser entendida como a indicação quantitativa da qualidade da medição, uma vez que quanto maiores os valores de incerteza com relação ao mensurando, maior a dúvida sobre o resultado obtido e, neste caso, o sistema de medição pode não ser o adequado para a devida análise (ISO, 2004).

O Guia para a Expressão das Incertezas de Medição (ISO, 2004), é um documento extensamente utilizado para exprimir as incertezas de medição e na avaliação dos resultados de sistemas de calibração e medição.

O método é baseado no modelamento de uma função relacional entre o mensurando e as variáveis de entrada, na forma da equação 2.1:

$$y = f(x_i) \quad (2.1)$$

A incerteza combinada padrão de y , por sua vez, pode ser escrita na forma da série abaixo 2.2:

$$u^2(y) = \sum_{i=1}^n \sum_{j=1}^n \frac{\partial f}{\partial x_i} \frac{\partial f}{\partial x_j} u(x_i, x_j) \quad (2.2)$$

Onde $\frac{\partial f}{\partial x_i}$ são os coeficientes de sensibilidade, $u(x_i, x_j)$ os coeficientes de covariância de x_i e x_j , respectivamente, com $u(x_i, x_i) = u^2(x_i)$, a variância de x_i .

Isso significa que a incerteza de medição é uma expressão matemática que correlaciona os valores das variáveis de entrada, verifica suas interações, dependendo, portanto do grau de assertividade do modelo e da quantidade de fontes de incerteza expressas.

Além disso, o ISO (2004) recomenda que a incerteza seja expressa com um intervalo de confiança (normalmente de 95,45%). Desta forma, o intervalo da incerteza expandida $U_{exp}(y)$ obtido é definido como o produto da incerteza padrão $u(y)$ por um fator de abrangência k , conforme equação 2.3.

$$U_{exp}(y) = k \cdot u(y) \quad (2.3)$$

2.7 Aprendizado de máquina

O desenvolvimento de novos produtos por meio dos métodos convencionais envolve uma série de etapas antes de sua produção industrial, como estruturação do projeto, levantamento de composições químicas potenciais, processamento em escala piloto e otimização das propriedades mecânicas por meio de simulações termomecânicas (TAVARES; FINAMOR; ZORZI, 2022).

Embora os mecanismos metalúrgicos envolvidos no processo de fabricação do aço sejam bem compreendidos na teoria, a determinação de uma relação matemática ou de um modelo de evolução microestrutural empírico é um processo complexo (XIE *et al.*, 2021). Por outro lado, tendo em vista que os processos industriais atualmente vêm sendo capazes de gerar e armazenar uma grande massa de dados, é possível utilizar ferramentas computacionais, em especial algoritmos de *machine learning*, para melhorar e acelerar os novos desenvolvimentos de aço ou mesmo otimizar e aperfeiçoar os ciclos de recozimento e composição química daqueles já existentes (TAVARES; FINAMOR; ZORZI, 2022). Toma-se como aprendizado de máquina ou *machine learning*, um conjunto de técnicas que possibilita a construção de modelos para predição de dados a partir de resultados passados, ou históricos. Nele, o algoritmo retorna prováveis conclusões baseadas na observação de padrões previamente conhecidos, obtidos por uma rotina de treinamento e validação a partir de um conjunto inicial de dados (TAVARES; FINAMOR; ZORZI, 2022; WEI *et al.*, 2019; MARSALLI, 2006).

Nos últimos anos, técnicas de **Inteligência Artificial (IA)** e de mineração de dados (*data mining*) têm sido cada vez mais empregadas em ciência dos materiais. Pode-se citar o desenvolvimento de inúmeras pesquisas envolvendo aprendizado de máquina na previsão ou melhoria de: microestruturas (CHOWDHURY *et al.*, 2016; ACAR, 2019); propriedades mecânicas em tração (TAVARES; FINAMOR; ZORZI, 2022; CARNEIRO *et al.*, 2021); de curvas de resfriamento contínuo (GENG *et al.*, 2020; BORBA; FINAMOR; VILARINHO, 2022), dentre outros (XIE *et al.*, 2021).

2.8 Mineração de dados e extração de conhecimento

Para Neto (2022), das metodologias empregadas em projetos de ciência dos dados e *machine learning*, o *Cross Industry Standard Process for Data Mining (CRISP DM)* é a mais utilizada. Essa metodologia possui um ciclo de desenvolvimento que consiste em seis etapas distintas: entendimento do negócio, entendimento dos dados, preparação dos dados, modelagem, avaliação e implementação, como ilustrado na Figura 7.


O objetivo do **CRISP DM** é possibilitar uma maior flexibilidade no processo de geração de conhecimento e na tomada de decisões baseada em dados (*data driven*), que não ocorre de forma linear, mas sim de forma cíclica, onde o retorno a um estágio pode ocorrer diversas vezes.

Percorrendo as etapas da metodologia tem-se (NETO, 2022):

2.8.1 Entendimento do negócio

Fase inicial do processo, focada nos problemas, objetivos e especificações com uma perspectiva de negócio. Essa etapa depende fortemente da formulação do problema a ser resolvido. Apesar de ser uma etapa inicial, essa fase deve acompanhar o ciclo de desenvolvimento ao longo de todo o projeto.

Figura 7 – Ciclo de desenvolvimento do modelo CRISP DM.



Fonte: Neto (2022).

2.8.2 Compreensão dos dados

Os dados são tidos como a matéria-prima para a solução do problema formulado anteriormente. Nessa fase, é analisada a qualidade dos dados de acordo com o problema, a exploração dos dados, a geração dos primeiros *insights* e a formulação de hipóteses.

2.8.3 Preparação dos dados

Consiste na geração de um banco de dados final a partir de dados não tratados, o que inclui etapas como seleção de atributos, integração, limpeza, transformação e avaliações estatísticas.

2.8.4 Modelagem

É a fase em que as técnicas de mineração de dados (data mining) e Machine Learning são aplicadas a fim de se descobrir padrões nos dados. Diversas técnicas podem ser empregadas, lembrando que a fase de preparação tem forte influência nessa etapa.

2.8.5 Avaliação

Os objetivos dessa fase são estimar os resultados do modelo construído anteriormente, estimar os melhores padrões e modelos, e validar os resultados às expectativas. A avaliação tenta ser o mais próximo da realidade, tendo-se o cuidado na seleção dos dados de teste e das métricas de avaliação utilizadas.

2.8.6 Implantação

Geralmente o modelo desenvolvido não é o final do projeto, mas sim, uma parte dele. Essa etapa normalmente é realizada com o apoio da equipe de tecnologia da informação, na criação de sistemas específicos, baseados no treinamento e validação citados nas etapas anteriores.

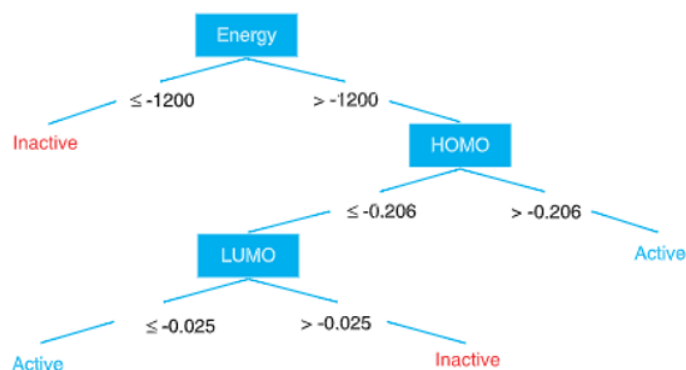
2.9 Modelos de machine learning

Nesta seção é apresentada uma breve revisão sobre os principais modelos de aprendizado de máquina, os quais podem ser classificados quanto à forma de aprendizado em: supervisionado, não supervisionado, semi-supervisionado e por reforço (LALAM *et al.*, 2019; RAVIKUMAR; RAMACHANDRAN; SUGUMARAN, 2011). O aprendizado supervisionado, pode ser imaginado como o “aprender com o auxílio de um professor”, isso é, as variáveis de saída de um treinamento são previamente estabelecidas. Em contraste, o aprendizado não-supervisionado é aquele em que as variáveis de resposta não são previamente conhecidas ou rotuladas. A aprendizagem semi-supervisionada é aquela em que uma porção dos dados de resposta é rotulada e o restante dos dados não é rotulado, sendo que a quantidade de dados não-rotulados se sobrepõe àqueles previamente rotulados. O aprendizado por reforço, ao invés de especificar ao modelo como produzir as respostas corretas, induz um sinal de reforço (recompensa) a uma ação tomada pelo agente de mudança.

2.9.1 Árvores de decisão (DT)

Decision Trees (DT) (OLIVEIRA, 2020; WEI *et al.*, 2019) são métodos de aproximação discreta, empregados tanto em regressão como em classificação, por meio da indução de um conjunto de regras observados no conjunto de treinamento. A Figura 8 ilustra uma arquitetura de árvore de decisão.

Figura 8 – Diagrama esquemático de uma DT.



Fonte: Wei *et al.* (2019).

As DTs possuem algumas vantagens, como a facilidade de interpretação dos resultados e de lidar com dados categóricos e quantitativos, além de não ser impactada com o emprego de variáveis com distribuições diferentes da normal e por valores discrepantes (*outliers*)(WEI *et al.*, 2019).

2.9.2 XGBoost - eXtreme Gradient Boosting

eXtreme Gradient Boosting são árvores de decisão com implementação de gradientes extremamente eficientes. Esse tipo de algoritmo vem ganhando notoriedade pela sua velocidade de treinamento e acurácia, sendo uma alternativa à modelos mais complexos (NENCHEV *et al.*, 2022).

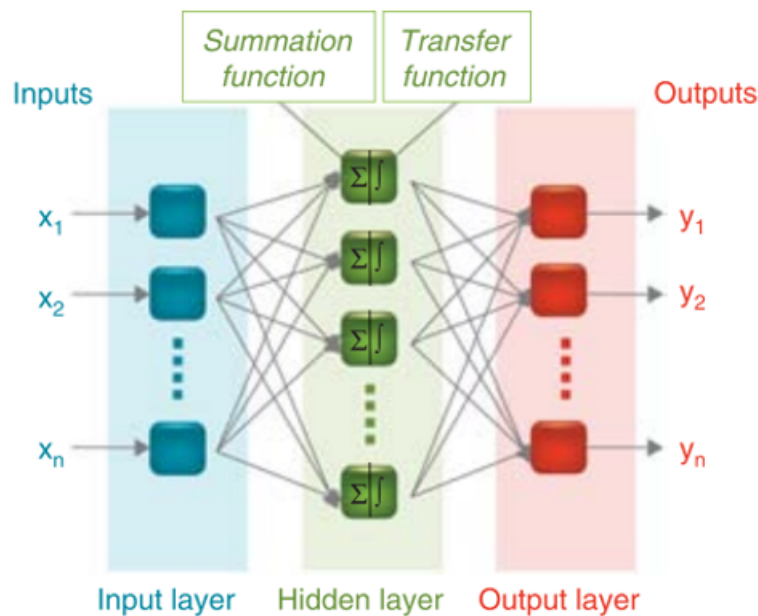
2.9.3 K vizinhos próximos (KNN)

Segundo Wei *et al.* (2019), o método de *K-Nearest Neighbors* (KNN) é baseado no agrupamento dos dados com características próximas. O algoritmo KNN não é influenciado pela distribuição dos dados, sendo, portanto, não-paramétrico. Sua implementação é fácil, porém para banco de dados extensos, possui alto custo computacional. Por se tratar de um método de cálculo de distâncias, o algoritmo KNN tende a ser sensível aos valores discrepantes ou extremos.

2.9.4 Redes Neurais Artificiais (ANN)

Redes Neurais Artificiais (ANN) foram estabelecidas como modelo matemático em 1943 por McCulloch e Pitts, onde foi proposto a descrição de um neurônio artificial que pudesse realizar funções lógicas (WEI *et al.*, 2019; MARSALLI, 2006). De modo geral, as ANNs são sistemas de processamento não-lineares e adaptativos formados por unidades básicas chamadas de percéptrons (neurônios ao comparativo biológico). Em uma ANN, os percéptrons são interconectados formando uma camada. No caso de uma arquitetura básica, ilustrada na Figura 9, essas interconexões consistem na construção de uma camada de entrada, um conjunto de camadas escondidas e uma de saída. A camada de entrada recebe as informações ou dados, enquanto as camadas intermediárias (escondidas) processam o sinal e o transmitem para a camada de saída, que é responsável por representar os resultados obtidos. De modo similar ao que ocorre com os neurônios biológicos, um percéptron só carregará a informação se ele for ativado, o que ocorre pelo uso de funções de ativação específicas.

Figura 9 – Arquitetura básica de uma ANN.



Fonte: Wei *et al.* (2019).

2.9.5 MARS

A Splines de Regressão Adaptativa Multivariada (MARS do inglês *Multivariate Adaptive Regression Splines*) é uma técnica de regressão não paramétrica, que usa funções base para ajustar a relação existente entre a variável dependente e seus preditores. Além disso, a técnica MARS modela a contribuição de cada variável individualmente e, também, as possíveis interações entre elas (CELERI, 2020).

2.9.6 GLMNET

GLMNET é um pacote criado para ajustar regressão linear generalizada por meio de penalização de máxima semelhança. Os regularizadores são computados por meio de penalidades do tipo Lasso ou Elastic Net, empregando um fator lambda de ajuste. O algoritmo é extremamente rápido, ajustando regressões lineares, logísticas e de Poisson (HASTIE; QIAN; TAY, 2021).

2.9.7 CUBIST

O modelo CUBIST é baseado em regras de associação, sendo uma extensão das árvores de decisão. Uma árvore cresce onde os terminais dos ramos contém modelos de regressão linear. Estes modelos são baseados em preditores utilizados nas podas dos ramos anteriores anteriores (KUHN *et al.*, 2012).

2.9.8 RANSAC

O RANSAC ou Consenso de Amostras Aleatórias é um algoritmo que trata amostras aleatórias do conjunto de dados total, e então identifica quais são os *outliers* para não utilizá-los na estimação dos parâmetros do modelo. O RANSAC serve de auxílio aos modelos de regressão, sendo que o RANSAC em conjunto com os modelos de regressão ajuda na obtenção de parâmetros que não tenham sido influenciados por *outliers* (POHLENZ *et al.*, 2020).

2.10 Métodos de avaliação dos modelos

Na metodologia CRISP DM, a fase mais importante após a preparação e o desenvolvimento dos modelos é a de avaliação dos modelos de predição. Nessa fase é feita a estimativa da performance de diferentes algoritmos a fim de escolher aquele que apresenta o melhor desempenho (NETO, 2022; TAVARES; FINAMOR; ZORZI, 2022; CARNEIRO *et al.*, 2021). Existem diversas formas de se quantificar a qualidade da resposta em problemas de regressão, como os parâmetros de erro *Mean Absolute Error* (MAE), *Mean Absolute Percentage Error* (MAPE) e *Root Mean Squared Error* (RMSE) e o parâmetro de ajuste R^2 , definidos pelas equações de 2.4 a 2.7, respectivamente:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y'_i - y_i| \quad (2.4)$$

$$MAPE = \frac{100}{n} \sum_{i=1}^n \frac{|y'_i - y_i|}{y_i} \quad (2.5)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y'_i - y_i)^2} \quad (2.6)$$

$$R^2 = \frac{[\sum_{i=1}^n (y_i - \bar{y})(y'_i - \bar{y}')]^2}{\sum_{i=1}^n (y_i - \bar{y})^2 \times \sum_{i=1}^n (y'_i - \bar{y}')^2} \quad (2.7)$$

Onde y_i e y'_i representam o valor real e o valor previsto, enquanto \bar{y} e \bar{y}' são as médias dos valores real e previsto, respectivamente.

Para Neto (2022), Tavares, Finamor e Zorzi (2022), Carneiro *et al.* (2021), o RMSE permite expressar o erro levando-se em consideração os efeitos dos pesos dos maiores erros de previsão, uma vez que se trata da diferença quadrática entre os valores reais e os previstos. Já os erros MAE e MAPE permitem quantificar o quão significativo são os erros de previsão quando comparados com os valores reais de modo absoluto e percentual, respectivamente. Por sua vez, o parâmetro de ajuste R^2 , indica o quanto o modelo foi capaz de explicar os dados testados.

Ressalta-se que baixos valores de erro RMSE, não necessariamente, estão vinculados a modelos bem ajustados, uma vez que os valores dessa medida são dependentes da escala do problema. Por exemplo, erros de $\pm 0,01$ em se tratando de deformação verdadeira, em um diagrama CLC, podem causar perturbações tão grandes quanto 10 a 20% do valor médio real dependendo do aço estudado. Nesse sentido, o emprego de outras medidas de avaliação de forma associada permite ter uma maior percepção da qualidade dos modelos empregados.

3 Metodologia

3.1 Construção da base de dados

Para o emprego dos algoritmos de **ML**, construiu-se, manualmente, uma base de dados constituída de propriedades mecânicas em tração e das **CLC** de diversos aços do setor automotivo, conforme especificação descrita na Tabela 1. Dessa forma, resultados discrepantes ou faltantes não foram considerados na construção da base.

Tabela 1 – Tabela de aços empregados no desenvolvimento do banco de dados de tração e **CLCs**.

Classe de aços	Limite de especificação	Faixa de espessura
	(MPa)	(mm)
<i>Dual Phase / Complex Phase</i>	490 a 980	0,60 a 2,00
TRIP	780	1,20 a 1,60
HSLA	350 a 460	0,65 a 4,00
IF / BH	140 a 240	0,50 a 2,00

A base de dados, contendo aproximadamente 100 observações, foi construída a partir de informações obtidas em ensaios de tração, compreendendo os valores dos limite de resistência (LR) e escoamento (LE), bem como os valores de anisotropia normal (\bar{r}) e expoente de encruamento (n), além do alongamento total (AL_T) das amostras. Os dados referentes às **CLCs** foram obtidos a partir dos pares de maior (ϵ_1) e menor (ϵ_2) deformação verdadeira pelo método de Nakajima (PAUL, 2021) à estrição, em conformidade com a norma ISO 12004-2 (ISO, 2008).

A dispersão dos resultados dos ensaios experimentais para o levantamento da **CLC** foi calculada a partir da dispersão dos pontos de ϵ_1 , considerando as diferentes trajetórias de deformação. A precisão do ensaio foi avaliada pela incerteza total expandida (U_{exp}) de medição, considerando a repetibilidade do ensaio, medida pelo desvio padrão da maior deformação ϵ_1 , a resolução das leituras de deformação do equipamento ($u_{res} = \text{resolução}/2$) e o desvio máximo associado ao equipamento de medição (u_{eq}). Desta forma, a incerteza expandida foi calculada pelo método definido na norma ISO GUM (ISO, 2004), empregando um intervalo de confiança de 95,45% e considerando a distribuição t-Student. O uso deste parâmetro como medida de precisão é baseado no trabalho de Janssens *et al.* (2001).

3.2 Normalização do banco de dados

Considerando que os dados de propriedades mecânicas possuem dimensões numéricas diferentes, variando da ordem de 0,05 (expoente de encruamento - n) a 1200 (limite de resistência - LR), e que tal diferença pode tornar a aprendizagem pouco eficiente (CHHEDA *et al.*, 2019; VANNUCCI *et al.*, 2021), empregou-se uma função de escalabilidade, conforme equação 3.1, transformando os dados em números de 0 a 1, a fim de minimizar quaisquer interferências.

$$x_t = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (3.1)$$

Onde, x_t é o novo valor de x após a transformação, em função dos pontos máximos e mínimos para cada variável contínua do banco de dados.

3.3 Modelamento

Para o modelamento da CLC, a partir dos dados de propriedades mecânicas em tração, foram empregados algoritmos de ML com método supervisionado de aprendizagem da biblioteca *scikit-learn* (BUITINCK *et al.*, 2013), além do uso do pacote Pandas (MCKINNEY, 2010) para a composição e tratamento de dados.

3.4 Divisão do banco de dados

O conjunto de dados foi dividido em três categorias: dados de treinamento, de validação e de teste. Os dados de treinamento foram usados para ajustar os modelos e os de validação para selecionar o modelo com base em seu melhor desempenho preditivo. Já os dados de teste, foram empregados para avaliar o erro de generalização (predição) daquele algoritmo de ML selecionado.

Como a base de dados empregada possui tamanho relativamente pequeno, utilizou-se a técnica de re-amostragem ou validação-cruzada k-fold (TAVARES; FINAMOR; ZORZI, 2022). A validação cruzada k-fold consiste na divisão aleatória do banco de treinamento original em k partes de tamanhos iguais, em que k-1 representam os dados de treinamento e a outra parte é destinada à estimativa de desempenho do algoritmo. Neste trabalho o valor de k foi fixado em 10.

3.5 Desempenho da previsão

A comparação do desempenho da previsão dos modelos foi feita pelo cálculo dos valores de **RMSE**, **MAPE**, **MAE** e R^2 , conforme as equações de 2.4 a 2.7. Por sua vez, os hiperparâmetros foram ajustados de modo a minimizar os valores de **RMSE** e aproximar os valores de R^2 à unidade, na tentativa de maximizar a correlação entre os valores previstos pelo modelo e os dados empíricos.

3.6 Previsão das curvas limite de conformação

Para verificar a capacidade de previsão do método proposto, as **CLCs** previstas pelos algoritmos foram comparadas aos valores obtidos experimentalmente para os aços DP780 e TRIP780, não participantes da etapa de aprendizagem e validação.

3.7 Incerteza de medição da CLC experimental

A dispersão dos resultados experimentais foi calculada a partir da dispersão dos pontos de maior (ϵ_1) e menor deformação (ϵ_2) verdadeiras por trajetória de deformação.

Como forma de avaliar a precisão do ensaio, foi adotada a incerteza total expandida (U_{exp}), considerando a repetibilidade do ensaio, medida pelo desvio padrão da maior deformação (ϵ_1), a resolução das leituras de deformação do equipamento (u_{res}) e o desvio máximo associado ao equipamento de medição (u_{eq}), considerado como 1% da deformação de engenharia, convertido para deformação real, conforme comunicado pela fabricante do equipamento.

Desta forma a incerteza expandida foi calculada pelo método definido na norma ISO GUM (ISO, 2004), empregando um intervalo de confiança de 95,45% e considerando uma distribuição t-Student.

4 Resultados

4.1 Construção da base de dados

Os dados de propriedades mecânicas em tração e os pares de pontos de maior (ϵ_1) e menor (ϵ_2) deformação verdadeiras estavam dispostos em diversos arquivos do tipo Microsoft Excel. Para o desenvolvimento da base de dados geral, criou-se uma rotina em *loop* para a abertura, seleção e adição dos dados num *database* próprio. Ao final dessa busca, o *database* contendo aproximadamente 100 observações, constando as propriedades citadas foi criado.

Para a seleção dos pares de pontos de menor e maior deformação verdadeira (ϵ_2 , ϵ_1), empregou-se o ponto de menor deformação verdadeira, ϵ_2 , nos extremos negativo e positivo da *CLC* como os valores referentes às trajetórias de deformação por embutimento e estiramento, respectivamente. Por sua vez, para o ponto CLC_0 , considerou-se o valor de ϵ_1 quando ϵ_2 fosse igual a zero.

4.2 Exploração da base de dados

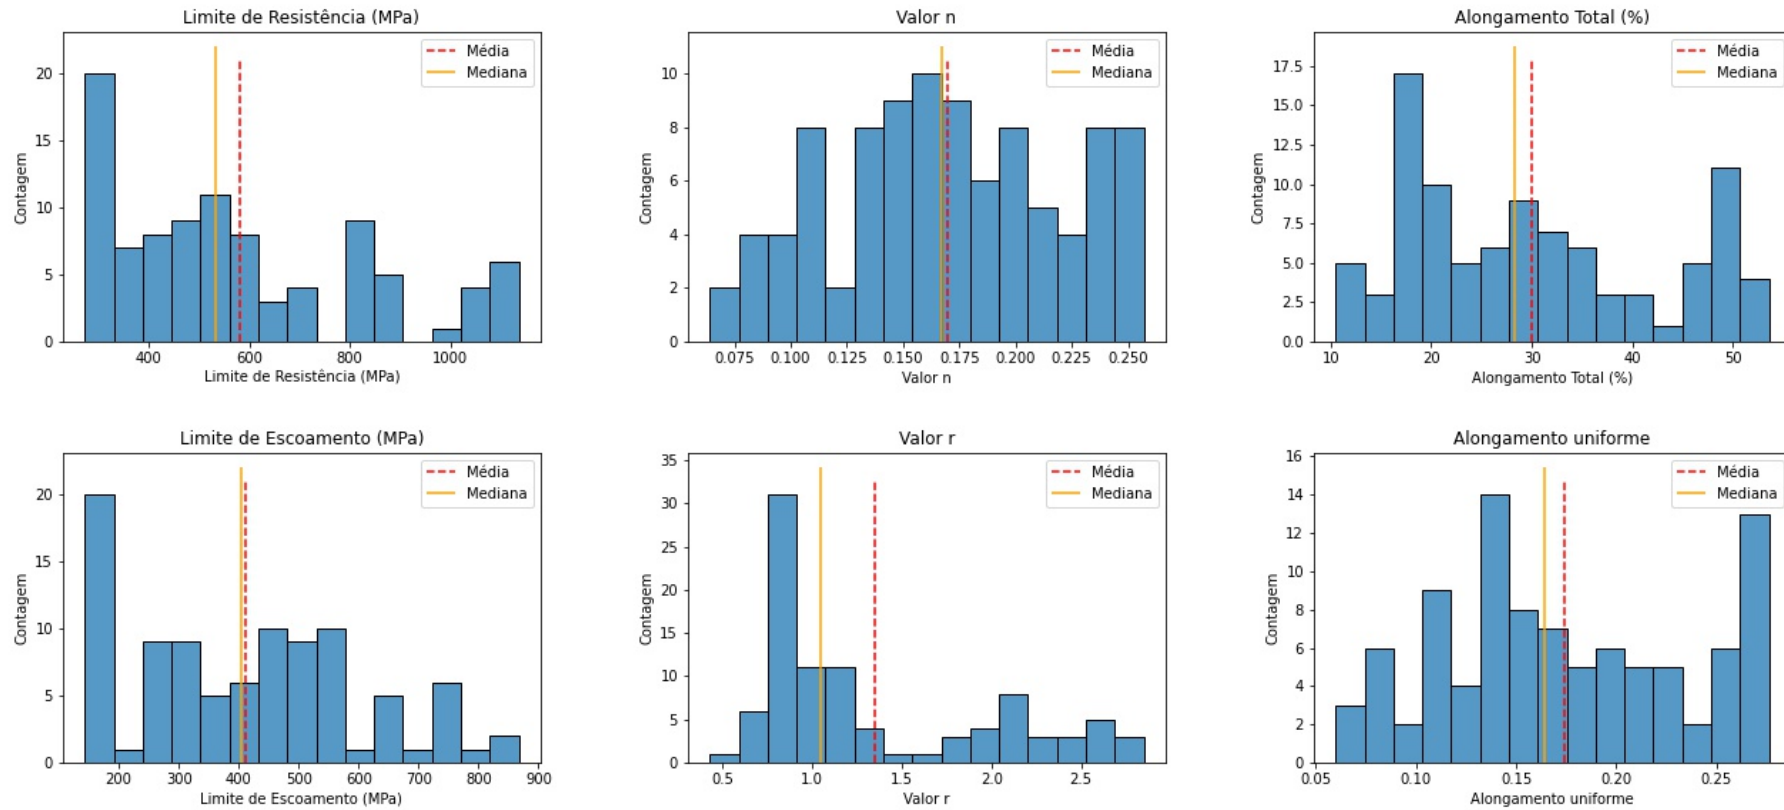
A avaliação da base de dados é crucial para o entendimento do problema, permitindo maior assertividade na escolha das técnicas a serem aplicadas e, assim, garantindo um melhor desempenho dos algoritmos nas etapas de aprendizagem e previsão (TAVARES; FINAMOR; ZORZI, 2022; CHHEDA *et al.*, 2019). Nessa etapa, foram utilizados os pacotes Pandas criado por McKinney (2010) e Seaborn desenvolvido por Waskom *et al.* (2017).

Observa-se nas Figuras de 10 a 11 que os valores estão distribuídos de maneira não normal, com concentração especial em aços com menor valor de limite de resistência e escoamento. Isso se dá em função da base de dados ser constituída majoritariamente por produtos de menor resistência mecânica, em especial por aços da classe *Interstitial Free (IF)*.

Por outro lado, observa-se na Figura 12, uma relação de produtos com menor espessura, compreendendo a maior parte da base de dados por produtos laminados a frio. Observa-se ainda, a presença de somente um produto com espessura acima de 3,5 mm. Nesse caso, optou-se pela remoção dos aços com espessura acima de 2,6 mm, a fim de se obter somente produtos laminados a frio, cujo processo de produção é consideravelmente diferente dos produtos laminados a quente de maior espessura. Essa remoção causou uma redução do banco de dados de 100 para 84 observações.

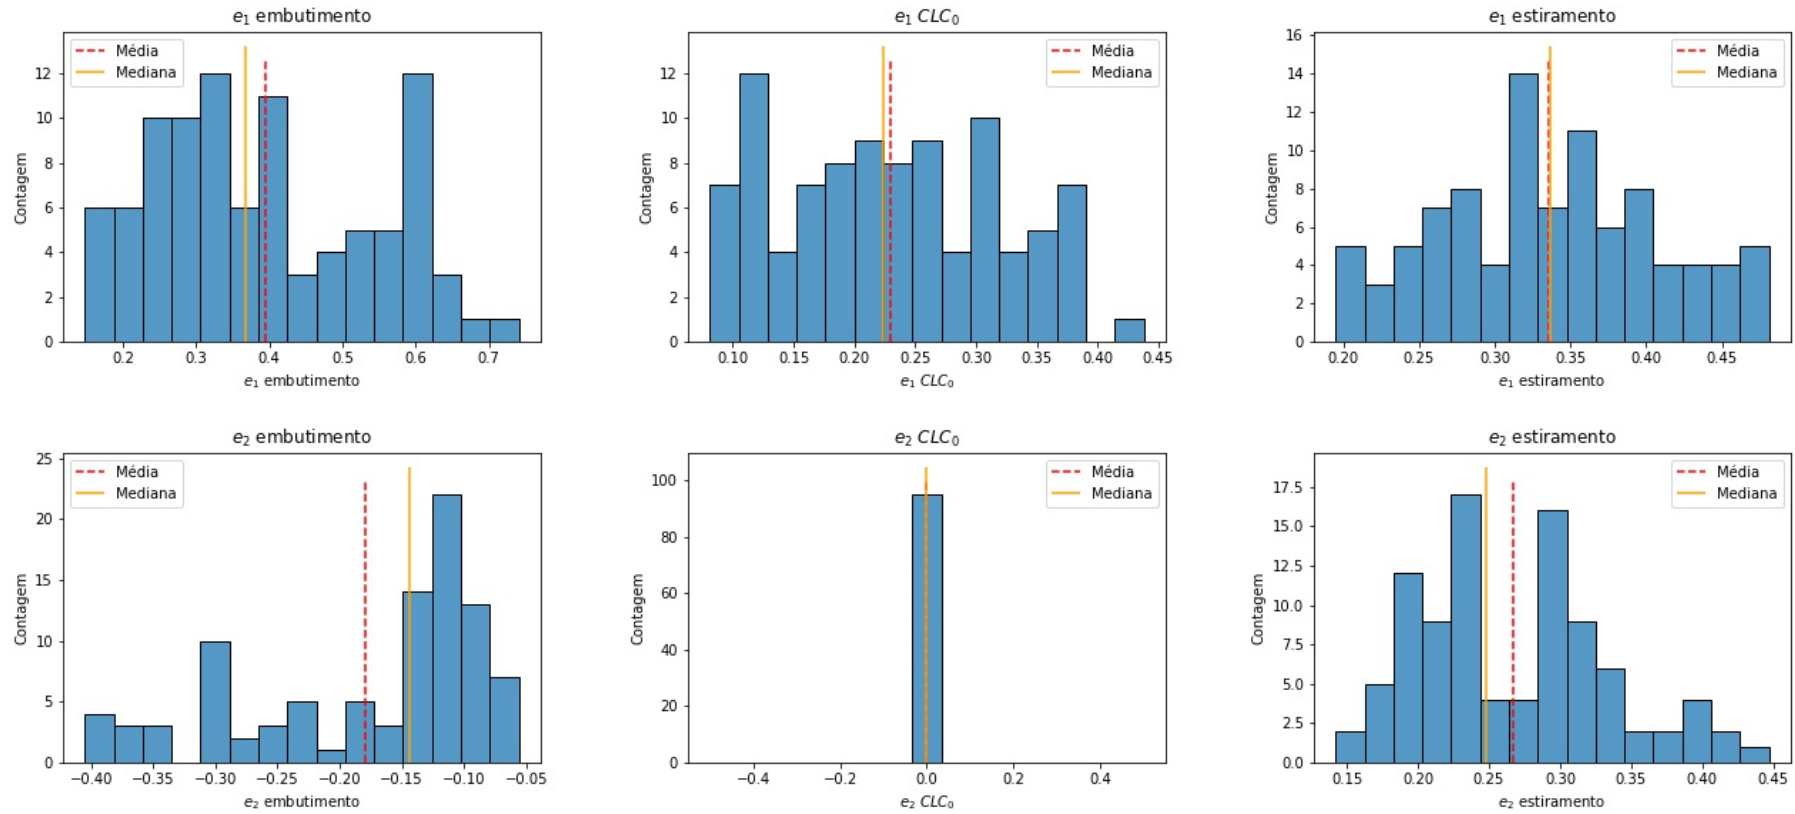
Observa-se, após a remoção dos aços com espessura acima de 2,6 mm, na Figura 13, o valor do coeficiente de Pearson entre as variáveis. A região dos valores de ϵ_2 para o ponto de CLC_0 são iguais a zero, o que implica na falta de relação entre as variáveis.

Figura 10 – Propriedades mecânicas distribuídas ao longo do banco de dados.



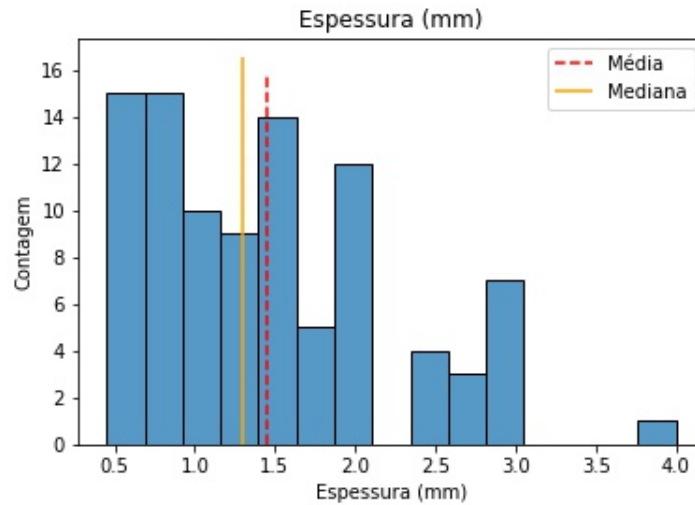
Fonte: Próprio autor.

Figura 11 – Distribuição dos valores de ε_1 e ε_2 ao longo do banco de dados, para diferentes trajetórias de deformação.



Fonte: Próprio autor.

Figura 12 – Distribuição dos valores de espessura (mm) ao longo do banco de dados.



Fonte: Próprio autor.


Por sua vez, a Figura 14 apresenta a descrição numérica do conjunto de dados obtido após a remoção dos valores de espessura acima de 2,60 mm.

A Figura 15 apresenta o gráfico de dispersão entre os valores de ϵ_1 e os de propriedades mecânicas em tração, obtidas por meio da exploração do banco de dados. As relações estão de acordo com o apresentado por Paul (2021), mostrando, por exemplo, um decaimento exponencial dos valores de ϵ_1 com o aumento dos valores de LE e LR e um aumento linear dos valores de ϵ_1 com o incremento dos valores de AL_T .

Entretanto, apesar do aumento esperado dos valores de ϵ_1 para a trajetória de deformação por embutimento ($\epsilon_2 < 0$) com o valor de \bar{r} e do aumento do valor de ϵ_1 com o aumento dos valores de n para a trajetória de estiramento ($\epsilon_2 > 0$), a relação entre os valores de \bar{r} e n com os valores de ϵ_1 não é linear, conforme ditado por Keeler e Kimchi (2017) e Schwindt *et al.* (2015). Esse fator pode estar relacionado com o tamanho e às diferentes classes de aços presentes no banco de dados, concentrado em aços de menor valor de resistência mecânica. Ademais, a forma de levantamento dos dados, principalmente a consideração de qual região de deformação se faz a leitura dos valores de n e \bar{r} , pode ter efeito considerável nos dados avaliados. Nesse caso, o valor de n , por exemplo, para os AHSS, é influenciado diretamente pela faixa de deformação utilizada para o seu cálculo (KEELER; KIMCHI, 2017), o que não é tão perceptível para os aços IF ou para os aços classificados como *High Strength Low Alloy (HSLA)*.

Nota-se, ainda, a presença de relações lineares fortes entre as variáveis, indicando alto grau de correlação entre elas, o que pode gerar perturbações no processo de treinamento dos algoritmos. Visando mitigar o efeito de correlação, foi conduzida uma redução da dimensionalidade dos dados empregando-se a *Análise de Componentes Principais (PCA)*.

Figura 13 – Heatmap mostrando a intensidade dos coeficientes de relação linear de Pearson.



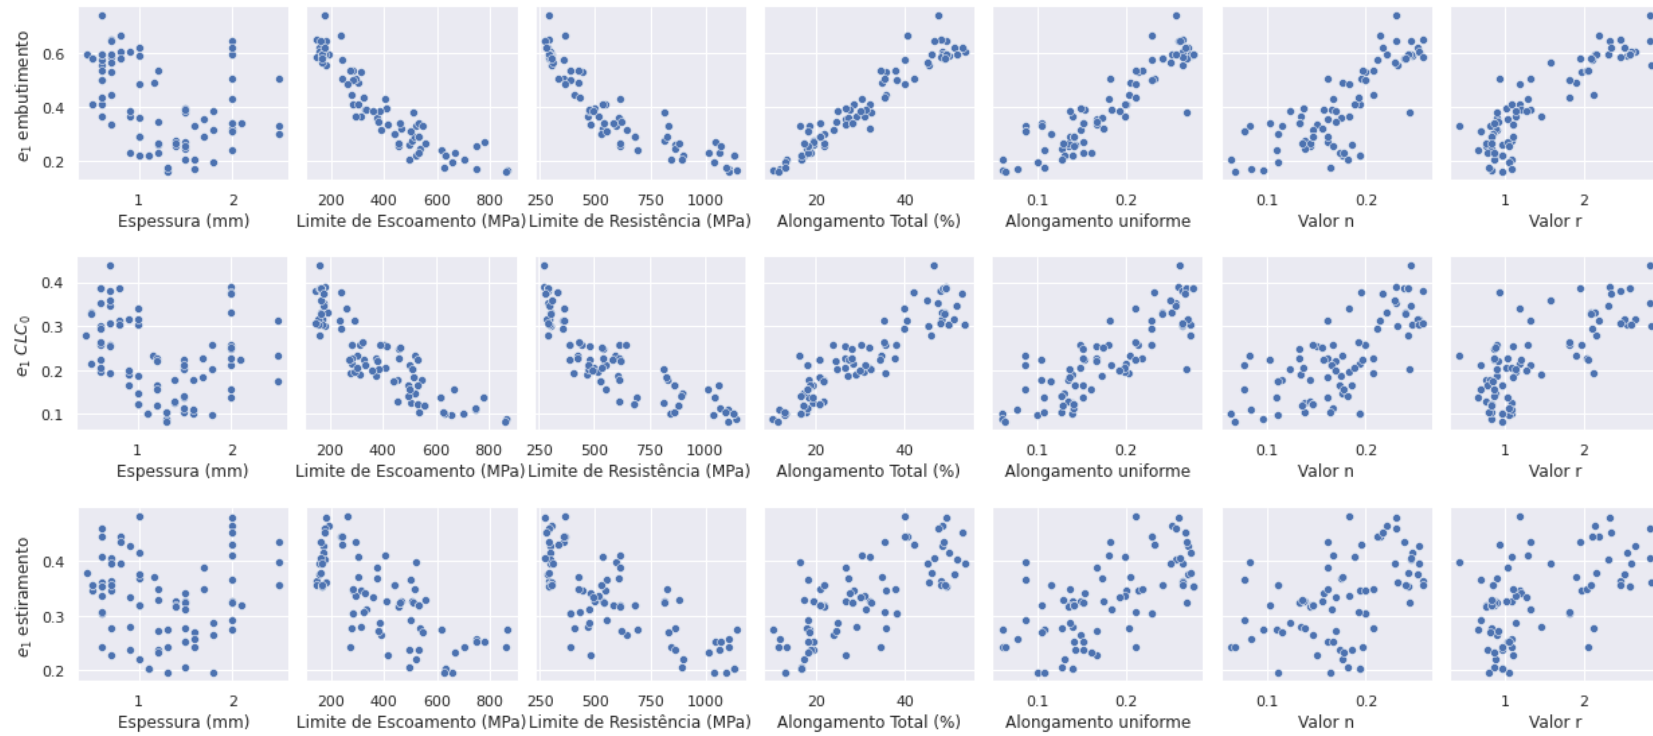
Fonte: Próprio autor.

Figura 14 – Estatística descritiva das variáveis utilizadas.

	esp	LE	LR	ALO	ALU	n_value	r_value	e2_emb	e1_emb	e2_clc0	e1_clc0	e2_est	e1_est
count	84.000000	84.000000	84.000000	84.000000	84.000000	84.000000	84.000000	84.000000	84.000000	84.0	84.000000	84.000000	84.000000
mean	1.253810	390.488512	574.782131	30.745405	0.179844	0.175560	1.425012	-0.190478	0.405697	0.0	0.228177	0.264976	0.332000
std	0.564728	186.102989	263.639032	12.621515	0.061982	0.050835	0.672229	0.097352	0.151905	0.0	0.089776	0.067216	0.071954
min	0.450000	143.000000	273.000000	10.467000	0.060000	0.064000	0.430000	-0.405000	0.158000	0.0	0.081000	0.142000	0.195000
25%	0.700000	239.750250	351.000000	19.542000	0.136000	0.142750	0.870750	-0.275500	0.285750	0.0	0.156000	0.213000	0.277250
50%	1.200000	376.500000	527.000000	28.400000	0.169500	0.175500	1.099500	-0.147000	0.373500	0.0	0.222000	0.247000	0.327000
75%	1.625000	518.750000	720.750000	40.900000	0.234250	0.214750	2.059500	-0.117000	0.559250	0.0	0.304250	0.308250	0.376000
max	2.500000	867.000000	1136.000000	53.600000	0.276000	0.257000	2.849000	-0.074000	0.741000	0.0	0.438000	0.447000	0.481000

Fonte: Próprio autor.

Figura 15 – Distribuição dos valores de ϵ_1 ao longo das trajetórias de deformação por embutimento, CLC_0 e estiramento.



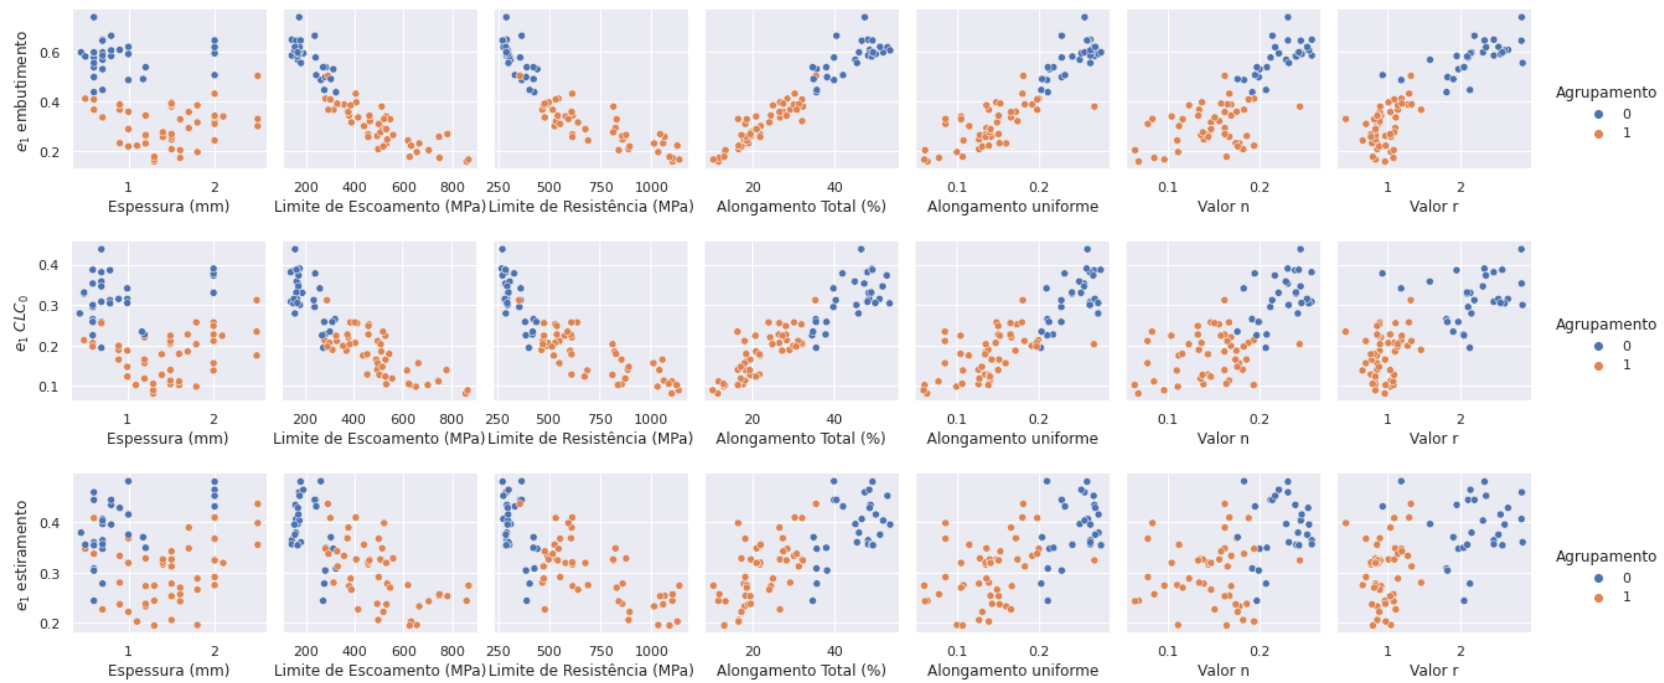
Fonte: Próprio autor.

4.3 Análise de agrupamentos

A partir do método *k-means* (WENZLICK *et al.*, 2022), uma análise de agrupamentos foi realizada na tentativa de verificar a aderência dos dados à grupos semelhantes, considerando as interações entre diferentes variáveis. Nesse caso, o objetivo foi entender como os aços do banco de dados podem ser agrupados baseados nas características de propriedades mecânicas em tração e dos pares de deformação empregados na construção da CLC. Para essa etapa empregou-se a biblioteca *sci-kit sklearn* (BUITINCK *et al.*, 2013) e para a seleção do número de agrupamentos ótimo o método do cotovelo, como descrito por Wenzlick *et al.* (2022).

A Figura 16 apresenta os gráficos de dispersão de propriedades mecânicas considerando os agrupamentos formados pela técnica *k-means*, tendo como número de agrupamentos ($k=2$). Observa-se que os agrupamentos obtidos podem ser considerados condizentes com os valores esperados em função das classes de aço pertencentes ao banco de dados. Nesse caso, materiais com valores elevados de LE e LR e menores valores de AL_T , n e \bar{r} foram considerados como um grupo (grupo 1), compreendendo em sua maioria os AHSS. De forma inversa, os materiais de menor resistência mecânica, coincidentes com os aços IF foram aglutinados em outro agrupamento (grupo 0).

Figura 16 – Distribuição dos valores de ϵ_1 ao longo das trajetórias de deformação por embutimento, CLC_0 e estiramento, considerando os agrupamentos formados por k-means.



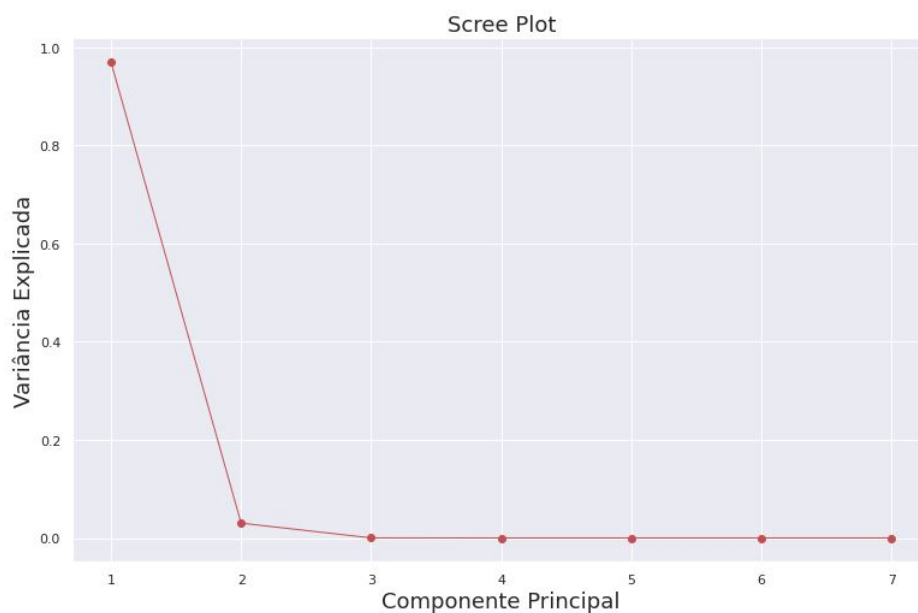
Fonte: Próprio autor.

4.4 Análise de componentes principais

A avaliação dos dados por meio da técnica **PCA** é uma ferramenta útil na redução da dimensionalidade dos dados.

A Figura 17 apresenta a relação entre o número de componentes principais e o grau de variância que essa componente explica. Observa-se que somente uma componente é responsável por 96,94% da variabilidade do banco de dados. Dessa forma, pode-se reduzir as variáveis de propriedades mecânicas em apenas uma componente principal sem perder a qualidade dos dados estudados.

Figura 17 – Screeplot - Variância explicada em função do número de componentes principais.

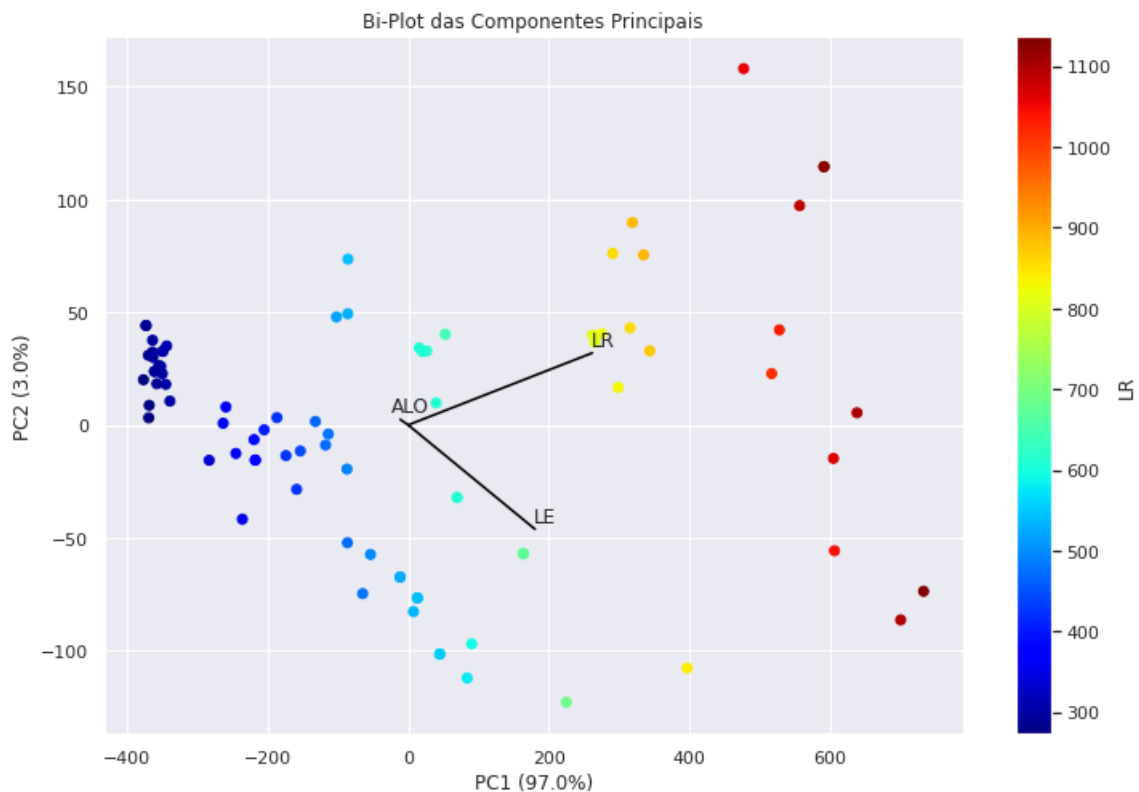


Fonte: Próprio autor.

Por sua vez, o gráfico de dispersão da Figura 18 apresenta a relação entre as componentes principais, **PC1** e **PC2**, e o peso das variáveis na composição das componentes principais (gráfico Biplot). Para a base de dados estudada, as informações sobre **LR** e **LE** são as que mais contribuem para explicar a variância dos dados. Entretanto, essas variáveis são altamente correlacionadas (coeficiente de correlação de Pearson $> 0,93$).

Visando aplicar a técnica de *eXplainable Artificial Intelligence (XAI)*, as informações de **LR**, **AL_T** e espessura foram consideradas para compor a base de dados final, a ser empregada no treinamento e validação dos modelos. Somou-se a estas variáveis as informações sobre agrupamento, obtidos na análise de agrupamentos.

Figura 18 – Biplot das componentes principais PC1 e PC2 e sua relação com as propriedades mecânicas em tração.



Fonte: Próprio autor.

4.5 Divisão da base de dados

Após a seleção das variáveis de propriedades mecânicas para compor a base de dados, foi feita a separação da base em termos de frações destinadas ao treinamento, validação e teste dos algoritmos.

Os dados para treinamento e validação foram divididos obedecendo a proporção de 75 e 25% da base de dados, respectivamente. A fim de se comparar o desempenho do algoritmo, os aços DP780 e TRIP780 foram removidos da base original, antes da etapa de treinamento e validação. Estes materiais pertencem à mesma classe de resistência e possuem espessuras relativamente similares (1,5 a 1,6 mm), porém, possuem valores de alongamento total diferentes. Ademais, a escolha desses aços se deu em função da limitação da equação de Keeler (KEELER; KIMCHI, 2017) para prever a CLC de AHSS.

Ademais, devido à quantidade limitada de dados disponíveis para treinamento, o método de validação cruzada, ou *k-fold cross validation*, como citado por Tavares, Finamor e Zorzi (2022) e Finamor, Wolff e Lage (2021), foi utilizado para melhorar e testar o desempenho dos algoritmos estudados, além de fornecer o intervalo de confiança da previsão.

4.6 Resultados de previsão

Para os diferentes modos de deformação, os algoritmos Regressão Linear (RL), Cubist (CUB) (QUINLAN *et al.*, 1992), XGBoost (XGB) (WEI *et al.*, 2019; NENCHEV *et al.*, 2022), *Random Forest* (RF) (WEI *et al.*, 2019), GLMNET, MARS, RANSAC e SVM (BUTINCK *et al.*, 2013) foram empregados visando a previsão dos valores da maior deformação verdadeira (ϵ_1). Em função da disponibilidade do banco de dados e, no intuito de reduzir a quantidade de modelos envolvidos na previsão da CLC, os valores da menor deformação verdadeira (ϵ_2) foram fixados em -0,12, 0 e 0,28 para as trajetórias de deformação por embutimento, CLC_0 e estiramento, respectivamente. Estes valores correspondem aos valores médios de ϵ_2 , obtidos para cada trajetória de deformação.

A fim de melhorar os resultados de previsão da maior deformação verdadeira (ϵ_1), para os algoritmos estudados, foi utilizado o método de *Grid Search* em conjunto com *K Fold Cross Validation* do *sci-kit learn* (BUTINCK *et al.*, 2013) para a seleção dos hiperparâmetros, visando a redução dos erros de previsão. Os gráficos de barras das Figuras de 19 a 21 apresentam os valores médios e o desvio padrão do erro MAE e do coeficiente de determinação R^2 dos modelos testados para os dados de ϵ_1 .


Observa-se que os modelos GLMNET, XGB e XGB, novamente, foram os que obtiveram os melhores desempenhos (menor valor de MAE e maior valor de R^2) para as trajetórias de deformação por embutimento, CLC_0 e estiramento, respectivamente. Apesar dos intervalos de erros se sobreporem, a previsão das CLCs dos aços não participantes das etapas de treinamento e validação, explicada no item 4.8, obteve os melhores resultados utilizando estes modelos, o que contribuiu para a sua seleção como modelos finais de previsão.

Os valores dos hiperparâmetros encontrados para estes modelos, bem como os gráficos de dispersão dos valores previstos e reais podem ser observados na Tabela 2 e Figura 22, respectivamente.

Dessa forma, o modelo final foi composto por diferentes algoritmos para as distintas trajetórias de deformação visando à determinação da CLC com menores taxas de erro.


A composição dos erros absolutos (MAE) e percentuais (MAPE) do modelo final, indicam valores relativamente baixos para as três trajetórias de deformação. Esses valores ficaram abaixo dos valores usuais da margem de segurança usualmente empregada para a utilização da CLC e que se correlacionam com a expectativa de variabilidade do ensaio e das propriedades do material são empregadas com margens de 10 a 20%.

Figura 19 – Valores dos desempenhos dos algoritmos para ϵ_1 , considerando a trajetória de deformação por embutimento.




Fonte: Próprio autor.

Figura 20 – Valores dos desempenhos dos algoritmos para ϵ_1 , considerando a trajetória de deformação por deformação plana (CLC_0).



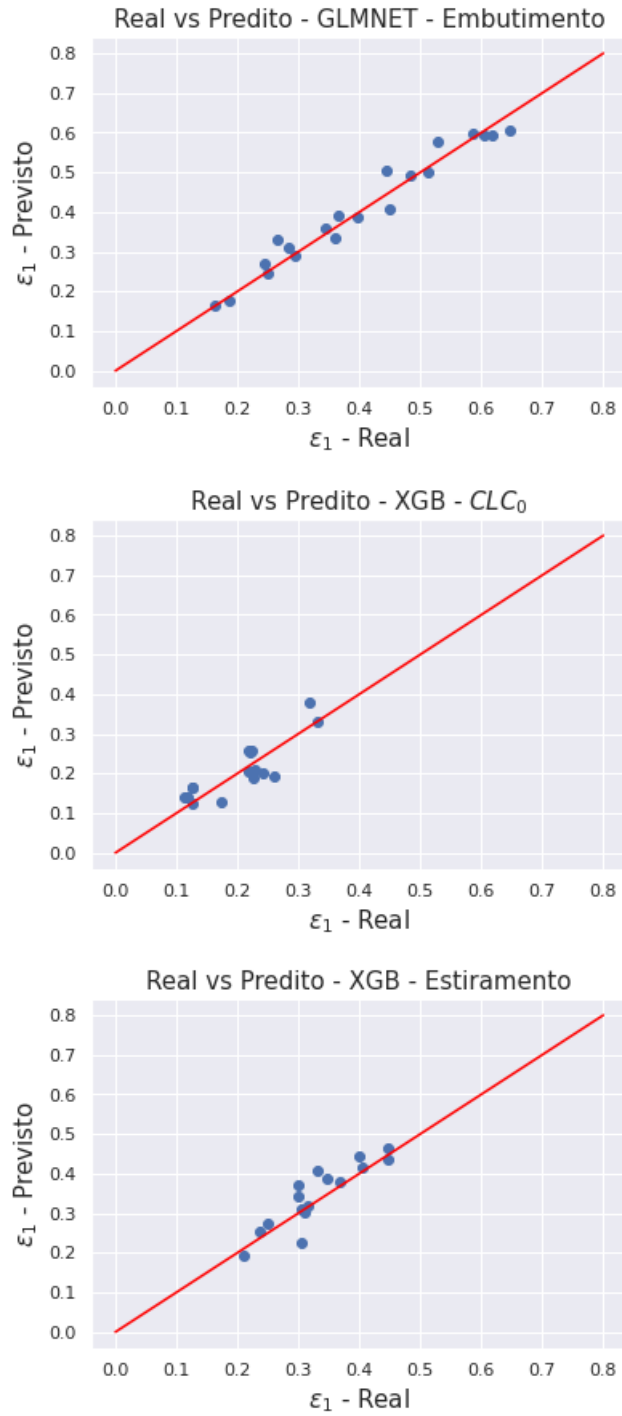
Fonte: Próprio autor.

Figura 21 – Valores dos desempenhos dos algoritmos para ϵ_1 , considerando a trajetória de deformação por estiramento.



Fonte: Próprio autor.

Figura 22 – Gráfico de dispersão entre os valores reais e previstos para a base de teste, considerando os valores de ϵ_1 para os modos de deformação por embutimento, deformação plana (CLC_0) e estiramento.



Fonte: Próprio autor.

Tabela 2 – Hiperparâmetros obtidos para os melhores modelos.

Modo de deformação	Modelo	Hiperparâmetros
Embutimento	GLMNET	'alpha': 0.001, 'l1_ratio': 0.0
CLC ₀	XGB	'colsample_bytree': 0.5, 'gamma': 0, 'learning_rate': 0.1, 'max_depth': 3, 'min_child_weight': 5, 'subsample': 1.0
Estiramento	XGB	'colsample_bytree': 1.0, 'gamma': 0, 'learning_rate': 0.1, 'max_depth': 3, 'min_child_weight': 10, 'subsample': 0.8

4.7 Incerteza de medição e intervalo de confiança da previsão

O cálculo da incerteza de medição normalmente é dividido em algumas etapas, como definição das fontes de incerteza, os cálculos da incerteza padrão e combinada, bem como o da incerteza final expandida (ISO, 2004).

Deste modo, por meio da combinação das incertezas de medição, foram definidas como as principais causas da variabilidade do ensaio a repetitividade e a reprodutibilidade (ou efeito do operador) do ensaio, bem como as incertezas associadas à máquina de ensaio (resolução, aferição, precisão e sistema tribológico).

Considerando-se a equação de Welch-Satterthwaite (ISO, 2004), é possível expandir a incerteza associada ao grau de liberdade efetivo e calcular o fator de abrangência k , associado à distribuição bicaudal t-Student.

Os valores da incerteza de medição e o intervalo de previsão do modelo de previsão final, calculado considerando o intervalo de confiança de 95% para os valores de RMSE, obtidos por trajetória de deformação, estão condensados na Tabela 3. Observa-se que os valores obtidos, tanto na incerteza de medição, quanto nos intervalo de previsão estão próximos, indicando que o modelo de previsão possui boa representatividade quanto aos valores previstos por trajetória de deformação.

Tabela 3 – Valores da incerteza expandida (U_{exp}) e do intervalo de previsão para o modelo final, para cada trajetória de deformação.

Trajетória de deformação	U_{exp}	Intervalo de Previsão
Embutimento	$\pm 0,025$	$\pm 0,029$
CLC ₀	$\pm 0,029$	$\pm 0,032$
Estiramento	$\pm 0,047$	$\pm 0,040$

4.8 Previsão da base de teste

As CLCs dos aços DP780 e TRIP780 foram previstos baseados nos valores de propriedades mecânicas em tração. Para avaliar a diferença entre os valores previstos e os dados reais, faixas referentes aos valores da **Incerteza de Medição (I.M.)** e do **Intervalo de Confiança da Previsão (I.C.)** foram adicionados. Esses resultados podem ser observados na Figura 23.

Nota-se que os dados previstos e reais estão próximos, com as faixas dos intervalos correspondentes aos valores de **I.C.** e **I.M.** sobrepostos para ambos os aços, o que indica uma correspondência entre os valores previstos e reais para os aços mencionados.

Dessa forma, pode-se inferir que o modelo proposto neste trabalho pode ser utilizado para a previsão da conformabilidade global dos aços, em especial os **AHSS**, por meio da previsão da **CLC**, utilizando somente os resultados de propriedades mecânicas em tração.

4.9 Explicação do modelo final

As Figuras de 24 a 26, apresentam os gráficos de enxame obtidos a partir do uso do pacote SHAP (LUNDBERG *et al.*, 2020).

A interpretação destas figuras, segundo Lundberg *et al.* (2020), pode ser feita observando a lista de variáveis mais importantes em ordem decrescente, vistas de cima para baixo. A cor indica uma ordem de grandeza da variável, isso é, cores vermelhas indicam valores altos e cores azuladas, valores mais baixos da variável.

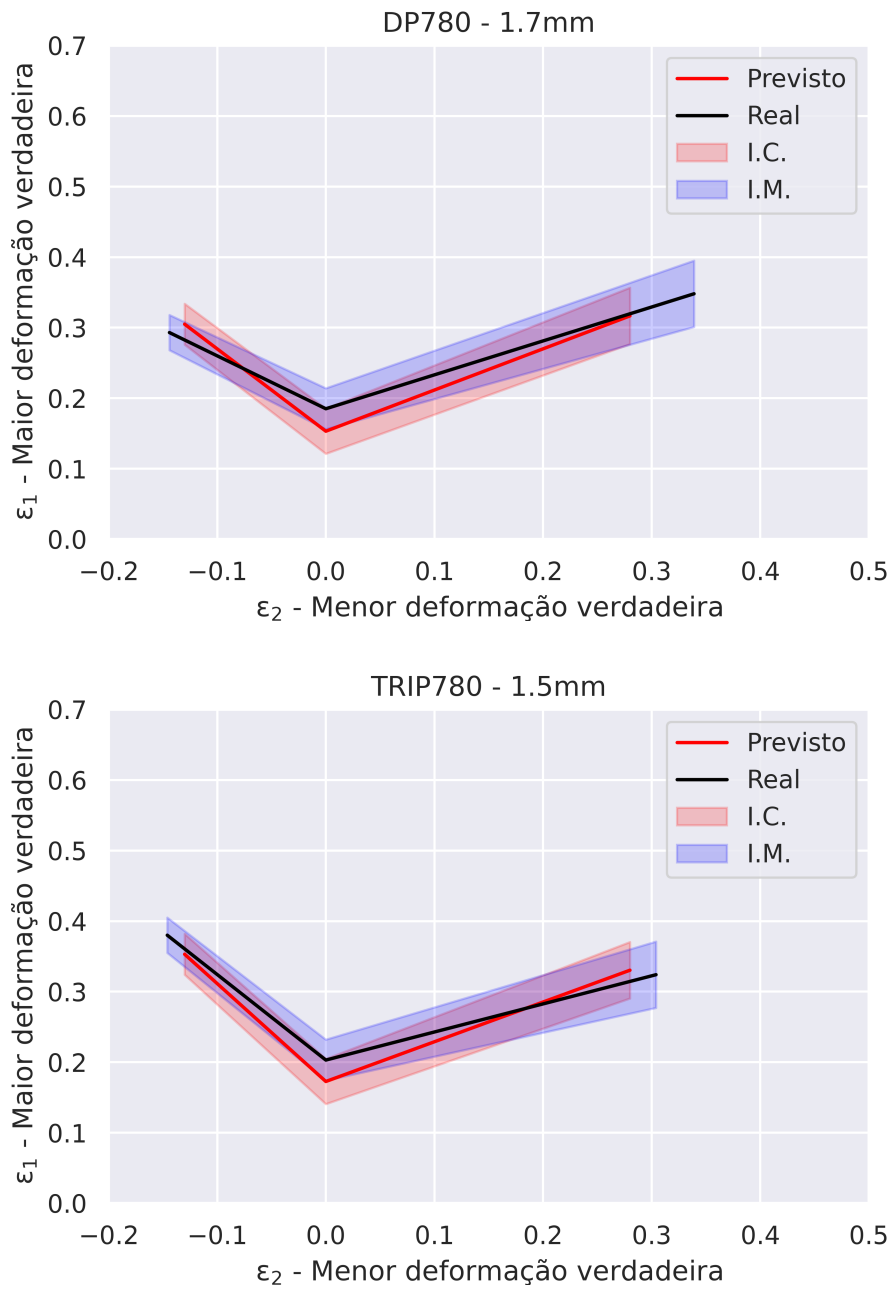
Dessa forma, nota-se, nas Figuras 24 e 25, a importância das variáveis **LR** e **ALO** (AL_T) para as trajetórias por embutimento e deformação plana (CLC_0), com pouco efeito da espessura e do agrupamento dos aços obtido pela técnica K-means, representadas pelas variáveis **esp**, **gr_0** e **gr_1**, respectivamente.

Observa-se, ainda, um efeito inversamente proporcional entre as variáveis **LR** e AL_T (**ALO**), como mostrado na Figura 13. Esse efeito já era esperado, uma vez que o aumento da resistência do material usualmente é acompanhado de uma diminuição da sua ductilidade (AL_T ou **ALO**).

Por outro lado, para a trajetória de deformação por estiramento, observa-se na Figura 26 que a variável mais importante foi o **ALO**, referente ao alongamento total (AL_T) e a espessura da chapa (**esp**). Nesse caso, conforme Keeler e Kimchi (2017), o incremento da espessura nessa região permite ao material suportar maiores deformações no plano antes de sua falha.


Infere-se que, a partir desses resultados, que os mecanismos propostos pela literatura, como em Keeler e Kimchi (2017) e Limbadri *et al.* (2015) foram observados pelos modelos de previsão, mesmo com um número pequeno de observações.

Figura 23 – Valores previstos e reais das *CLCs*, considerando a incerteza de medição (IM) e o intervalo de previsão (IP) para os aços DP780 e TRIP780.




Fonte: Próprio autor.

Figura 24 – Valores de Shapley obtidos para a trajetória de deformação de embutimento, a partir do pacote SHAP (LUNDBERG *et al.*, 2020), considerando o modelo XGB.




Fonte: Próprio autor.

Figura 25 – Valores de Shapley obtidos para a trajetória de deformação plana (CLC_0), a partir do pacote SHAP (LUNDBERG *et al.*, 2020), considerando o modelo XGB.



Fonte: Próprio autor.

Figura 26 – Valores de Shapley obtidos para a trajetória de deformação de estiramento, a partir do pacote SHAP (LUNDBERG *et al.*, 2020), considerando o modelo SVM.



Fonte: Próprio autor.

5 Considerações Finais

Para o desenvolvimento do modelo de previsão da conformabilidade global dos aços, avaliada por meio da CLC, dados de propriedades mecânicas em tração e os pares de maior e menor deformação verdadeira (ϵ_1 , ϵ_2) considerando as trajetórias de deformação por embutimento, deformação plana e estiramento foram utilizadas. Além disso, visando comparar os resultados de previsão com os dados de ensaio, o cálculo da incerteza de medição foi desenvolvido considerando as recomendações das normas de ensaio.

Os resultados de previsão das CLCs dos aços DP780 e TRIP780, obtidos a partir das propriedades mecânicas em tração foram consistentes com os dados experimentais. O erro entre os resultados experimentais e aqueles obtidos pelo modelo final de previsão foram suficientemente baixos, próximos aos valores de incerteza de medição do ensaio de levantamento das curvas e menores que os valores usuais da margem de segurança (10 a 20% em valores relativos).

Considerando que alguns algoritmos de previsão são "caixas pretas", o uso de técnicas explicativas, ou XAI, permitiram obter as variáveis de maior impacto na previsão dos pares de deformação (ϵ_2 , ϵ_1) por trajetória de deformação na composição da CLC. Os valores de alongamento total (AL_T) e limite de resistência (LR) foram as principais variáveis para as trajetórias de embutimento e deformação plana e os valores de alongamento total (AL_T) e espessura para a trajetória de deformação por estiramento. Estes resultados foram condizentes com o comportamento esperado para os aços estudados, mesmo considerando a quantidade limitada de dados de treinamento.

Os resultados sugerem a possibilidade de implantação deste tipo de abordagem em novos desenvolvimentos de aços e na avaliação de problemas relativos à conformabilidade dos aços, reduzindo os custos de ensaios, agilizando as avaliações de propriedades de conformação, além de ser uma ferramenta útil para as estamparias no ajuste dos parâmetros de estampagem.

Referências

- ABBASI, M.; SHAFAT, M. A.; KETABCHI, M.; HAGHSHENAS, D. F.; ABBASI, M. Application of the gtn model to predict the forming limit diagram of if-steel. **Journal of Mechanical science and Technology**, Springer, v. 26, n. 2, p. 345–352, 2012.
- ACAR, P. Machine learning approach for identification of microstructure–process linkages. **AIAA Journal**, American Institute of Aeronautics and Astronautics, v. 57, n. 8, p. 3608–3614, 2019.
- BANABIC, D. **Sheet metal forming processes: constitutive modelling and numerical simulation**. [S.l.]: Springer Science & Business Media, 2010. ISBN 3-540-88113-1.
- BERG, F. D. V. D.; KOK, P. J. J.; YANG, H.; AARNTS, M. P.; MEILLAND, P.; KEBE, T.; STOLZENBERG, M.; KRIX, D.; ZHU, W.; PEYTON, A. J.; MARTINEZ-DE-GUERENU, A.; GUTIERREZ, I.; JORGE-BADIOLA, D.; MALMSTRÖM, M.; VOLKER, A.; DUIJSTER, A.; WIRDELIUS, H.; BOSTRÖM, A.; MOCCI, C.; VANNUCCI, M.; COLLA, V.; DAVIS, C.; ZHOU, L.; SCHMIDT, R.; LABBÉ, S.; REBOUD, C.; SKARLATOS, A.; LECONTE, V.; LOMBARD, P. Product uniformity control - A research collaboration of european steel industries to non-destructive evaluation of microstructure and mechanical properties. In: . [s.n.], 2018. p. 120–129. Disponível em: <http://urn.kb.se/resolve?urn=urn:nbn:se:ri:diva-34558>.
- BORBA, T. M. D.; FINAMOR, F. P.; VILARINHO, L. O. Previsão das temperaturas de início e fim de transformação de diferentes tipos de metais de solda através de técnicas de machine learning. **Contribuição técnica ao 75 Congresso Anual da ABM**, 2022.
- BUITINCK, L.; LOUPPE, G.; BLONDEL, M.; PEDREGOSA, F.; MUELLER, A.; GRISEL, O.; NICULAE, V.; PRETTENHOFER, P.; GRAMFORT, A.; GROBLER, J.; LAYTON, R.; VANDERPLAS, J.; JOLY, A.; HOLT, B.; VAROQUAUX, G. API design for machine learning software: experiences from the scikit-learn project. In: **ECML PKDD Workshop: Languages for Data Mining and Machine Learning**. [S.l.: s.n.], 2013. p. 108–122.
- CARNEIRO, M. V.; SALIS, T. T.; ALMEIDA, G. M.; BRAGA, A. P. Prediction of mechanical properties of steel tubes using a machine learning approach. **Journal of Materials Engineering and Performance**, Springer, v. 30, n. 1, p. 434–443, 2021.
- CELERI, M. d. O. Splines de regressão adaptativa multivariada na predição genômica. Universidade Federal de Viçosa, 2020.
- CHEONG, K.; BUTCHER, C.; DYKEMAN, J. The influence of the through-thickness strain gradients on the fracture characterization of advanced high-strength steels. **SAE International Journal of Materials and Manufacturing**, v. 11, n. 4, p. 541–552, 2018. ISBN: 1946-3979 Publisher: JSTOR.
- CHHEDA, A. M.; NAZRO, L.; SEN, F. G.; HEGADEKATTE, V. Prediction of forming limit diagrams using machine learning. In: IOP PUBLISHING. **IOP Conference Series: Materials Science and Engineering**. [S.l.], 2019. v. 651, n. 1, p. 012107.
- CHOWDHURY, A.; KAUTZ, E.; YENER, B.; LEWIS, D. Image driven machine learning methods for microstructure recognition. **Computational Materials Science**, Elsevier, v. 123, p. 176–187, 2016.

COLLA, V.; CATENI, S.; MADDALONI, A.; VIGNALI, A. A Modular Machine-Learning-Based Approach to Improve Tensile Properties Uniformity Along Hot Dip Galvanized Steel Strips for Automotive Applications. **Metals**, v. 10, n. 7, p. 923, jul. 2020. ISSN 2075-4701. Number: 7 Publisher: Multidisciplinary Digital Publishing Institute. Disponível em: <<https://www.mdpi.com/2075-4701/10/7/923>>.

FINAMOR, F.; WOLFF, M.; LAGE, V. Prediction of forming limit diagrams from tensile tests of automotive grade steels by a machine learning approach. In: IOP PUBLISHING. **IOP Conference Series: Materials Science and Engineering**. [S.l.], 2021. v. 1157, n. 1, p. 012080.

GENG, X.; WANG, H.; XUE, W.; XIANG, S.; HUANG, H.; MENG, L.; MA, G. Modeling of cct diagrams for tool steels using different machine learning techniques. **Computational Materials Science**, Elsevier, v. 171, p. 109235, 2020.

HANCE, B. M. Advanced high strength steel: Deciphering local and global formability. In: **Proc. International Automotive Body Congress, Dearborn, MI**. [S.l.: s.n.], 2016.

HASTIE, T.; QIAN, J.; TAY, K. An introduction to glmnet. **CRAN R Repository**, 2021.

HICKEY, K. **Global vs Local Formability**. 2021. Disponível em: <<https://ahssinsights.org/forming/formability/global-vs-local-formability/>>.

HOSFORD, W. F.; CADDELL, R. M. **Metal forming: mechanics and metallurgy**. [S.l.]: Cambridge university press, 2011. ISBN 1-139-49743-X.

ISO. **Guide to the expression of uncertainty in measurement (GUM)-Supplement 1: Numerical methods for the propagation of distributions**. Geneva: International Organization for Standardization, 2004. ISO draft guide DGUIDE99998.

ISO, E. 12004-2: 2008: Metallic materials Determination of forming-limit curves. **Sheet and strip, Determination of forming-limit curves**, 2008.

JANSSENS, K.; LAMBERT, F.; VANROSTENBERGHE, S.; VERMEULEN, M. Statistical evaluation of the uncertainty of experimentally characterised forming limits of sheet steel. **Journal of Materials Processing Technology**, Elsevier, v. 112, n. 2-3, p. 174–184, 2001.

KEELER, S.; KIMCHI, M. Mooney. **Advanced High-Strength Steels Application Guidelines**, 2017.

KUHN, M.; WESTON, S.; KEEFER, C.; COULTER, N. Cubist models for regression. **R package Vignette R package version 0.0**, Citeseer, v. 18, p. 480, 2012.

LALAM, S.; TIWARI, P. K.; SAHOO, S.; DALAL, A. K. Online prediction and monitoring of mechanical properties of industrial galvanised steel coils using neural networks. **Ironmaking & Steelmaking**, v. 46, n. 1, p. 89–96, jan. 2019. ISSN 0301-9233. Publisher: Taylor & Francis _eprint: <https://doi.org/10.1080/03019233.2017.1342424>. Disponível em: <<https://doi.org/10.1080/03019233.2017.1342424>>.

LIMBADRI, K.; GANGADHAR, J.; RAM, A. M.; SINGH, S. K. Review of Formability in Relation to Texture. **Materials Today: Proceedings**, v. 2, n. 4-5, p. 2198–2204, 2015. ISBN: 2214-7853 Publisher: Elsevier.

- LUNDBERG, S. M.; ERION, G.; CHEN, H.; DEGRAVE, A.; PRUTKIN, J. M.; NAIR, B.; KATZ, R.; HIMMELFARB, J.; BANSAL, N.; LEE, S.-I. From local explanations to global understanding with explainable ai for trees. **Nature Machine Intelligence**, Nature Publishing Group, v. 2, n. 1, p. 2522–5839, 2020.
- MARSALLI, M. McCulloch-pitts neurons. In: **The 2008 Annual Meeting of the consortium on cognitive science instruction (ccsi)**. [S.l.: s.n.], 2006. v. 1161, p. 1162.
- MCKINNEY Wes. Data Structures for Statistical Computing in Python. In: WALT Stéfan van der; MILLMAN Jarrod (Ed.). **Proceedings of the 9th Python in Science Conference**. [S.l.: s.n.], 2010. p. 56 – 61.
- MINH, H. V.; SOWERBY, R.; DUNCAN, J. Variability of forming limit curves. **International Journal of Mechanical Sciences**, Elsevier, v. 16, n. 1, p. 31–44, 1974.
- NENCHEV, B.; TAO, Q.; DONG, Z.; PANWISAWAS, C.; LI, H.; TAO, B.; DONG, H. Evaluating data-driven algorithms for predicting mechanical properties with small datasets: A case study on gear steel hardenability. **International Journal of Minerals, Metallurgy and Materials**, Springer, v. 29, n. 4, p. 836–847, 2022.
- NETO, P. F. d. S. Implementação de business intelligence através da metodologia crisp-dm para apoiar tomada de decisão estratégica em uma corretora de imóveis. 2022.
- OLIVEIRA, T. A. d. **Árvores de Classificação e Regressão**. 2020. Notas de aula, UFOP (Universidade Federal de Ouro Preto), João Monlevade, Brasil.
- PAUL, S. K. Controlling factors of forming limit curve: A review. **Advances in Industrial and Manufacturing Engineering**, v. 2, p. 100033, maio 2021. ISSN 26669129. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S2666912921000039>>.
- POHLENZ, V. *et al.* Aplicação de machine learning e ferramentas estatísticas para modelagem e análise de falhas em aerogeradores. Florianópolis, SC, 2020.
- QUINLAN, J. R. *et al.* Learning with continuous classes. In: WORLD SCIENTIFIC. **5th Australian joint conference on artificial intelligence**. [S.l.], 1992. v. 92, p. 343–348.
- RAVIKUMAR, S.; RAMACHANDRAN, K.; SUGUMARAN, V. Machine learning approach for automated visual inspection of machine components. **Expert systems with applications**, Elsevier, v. 38, n. 4, p. 3260–3266, 2011.
- SCHWINDT, C. D.; STOUT, M.; IURMAN, L.; SIGNORELLI, J. W. Forming limit curve determination of a dp-780 steel sheet. **Procedia Materials Science**, Elsevier, v. 8, p. 978–985, 2015.
- STRANO, M.; COLOSIMO, B. M. Logistic regression analysis for experimental determination of forming limit diagrams. **International Journal of Machine Tools and Manufacture**, Elsevier, v. 46, n. 6, p. 673–682, 2006.
- TAVARES, T. B.; FINAMOR, F. P.; ZORZI, J. C. de S. Mechanical properties prediction of dual phase steels using machine learning. **Tecnologia em Metalurgia, Materiais e Mineração**, ABM-Associação Brasileira de Metalurgia, Materiais e Mineração, v. 19, p. 0–0, 2022.
- TISZA, M.; KOVÁCS, Z. P. New methods for predicting the formability of sheet metals. **Production Processes and Systems**, v. 5, n. 1, p. 45–54, 2012.

TORSTENSSON, A. **Comparison of Accuracy in Sheet Metal Forming Simulation Software**. 2022.

Usinas Siderúrgicas de Minas Gerais - Usiminas. **Fascículo de informação técnica - Conformação na Prensa**. [S.l.: s.n.], 1984. Vol. 6.

VANNUCCI, M.; COLLA, V.; MOCCI, C.; BERG, V.; Fintelman; Yang. **Prediction of steel coils mechanical properties and microstructure by using deep learning and advanced data preprocessing techniques**. [S.l.: s.n.], 2021. Pages: 119.

WASKOM, M.; BOTVINNIK, O.; O'KANE, D.; HOBSON, P.; LUKAUSKAS, S.; GEMPERLINE, D. C.; AUGSPURGER, T.; HALCHENKO, Y.; COLE, J. B.; WARMENHOVEN, J.; RUITER, J. de; PYE, C.; HOYER, S.; VANDERPLAS, J.; VILLALBA, S.; KUNTER, G.; QUINTERO, E.; BACHANT, P.; MARTIN, M.; MEYER, K.; MILES, A.; RAM, Y.; YARKONI, T.; WILLIAMS, M. L.; EVANS, C.; FITZGERALD, C.; BRIAN; FONNESBECK, C.; LEE, A.; QALIEH, A. **mwaskom/seaborn: v0.8.1 (September 2017)**. Zenodo, 2017. Disponível em: <<https://doi.org/10.5281/zenodo.883859>>.

WEI, J.; CHU, X.; SUN, X.-Y.; XU, K.; DENG, H.-X.; CHEN, J.; WEI, Z.; LEI, M. Machine learning in materials science. **InfoMat**, Wiley Online Library, v. 1, n. 3, p. 338–358, 2019.

WENLONG, S.; XIAOKAI, C.; LU, W. Analysis of energy saving and emission reduction of vehicles using light weight materials. **Energy Procedia**, Elsevier, v. 88, p. 889–893, 2016.

WENZLICK, M.; MAMUN, O.; DEVANATHAN, R.; ROSE, K.; HAWK, J. Assessment of outliers in alloy datasets using unsupervised techniques. **JOM**, Springer, p. 1–14, 2022.

WESTHÄUSER, S.; SCHNEIDER, M.; DENKS, I. A. On the relation of local formability and edge crack sensitivity. In: **International Conference on Steels in Cars and Trucks**. [S.l.: s.n.], 2017.

XIE, Q.; SUVARNA, M.; LI, J.; ZHU, X.; CAI, J.; WANG, X. Online prediction of mechanical properties of hot rolled steel plate using machine learning. **Materials & Design**, Elsevier, v. 197, p. 109201, 2021.