

AJUSTE DO FATOR K NO DOBRAMENTO DE CHAPAS METÁLICAS: REVISÃO CRÍTICA E PROPOSTA DE MODELO BASEADO EM VARIÁVEIS FÍSICO-QUÍMICAS

**K-FACTOR ADJUSTMENT IN SHEET METAL BENDING: CRITICAL REVIEW
AND PROPOSAL OF A MODEL BASED ON PHYSICOCHEMICAL VARIABLES**

**AJUSTE DEL FACTOR K EN EL DOBLADO DE CHAPA METÁLICA: REVISIÓN
CRÍTICA Y PROPUESTA DE UN MODELO BASADO EN VARIABLES
FISICOQUÍMICAS**

Fábio Lodi¹, Lisiane Trevisan², Paulo Janissek³, Juliano Cantarelli Toniolo⁴

DOI: 10.54899/dcs.v22i81.3248

Recibido: 24/08/2025 | **Aceptado:** 25/08/2025 | **Publicación en línea:** 04/09/2025.

RESUMO

O dobramento de chapas metálicas é um processo amplamente utilizado na indústria, no qual o controle preciso de parâmetros como o fator K é fundamental para garantir qualidade dimensional e minimizar desperdícios. Este artigo apresenta uma revisão sistemática da literatura sobre métodos de previsão de retorno elástico (springback) e estratégias de correção do fator K, com ênfase no período de 1995 a 2025. Após extensa pesquisa bibliográfica, quinze estudos foram selecionados para compor o referencial teórico deste artigo, seguindo critérios de relevância, rigor metodológico e revisão por pares. Os métodos predominantes nos estudos revisados incluem simulações por elementos finitos (MEF), redes neurais artificiais, modelagens multiescalares e abordagens experimentais, sendo este último ainda relevante para calibração de modelos. A análise revela uma tendência crescente de uso de técnicas computacionais complexas, porém com limitações de custo e acessibilidade. Como contribuição, este trabalho propõe as bases conceituais para o desenvolvimento de uma equação de correção simplificada do fator K, fundamentada em variáveis físico-químicas e microestruturais dos materiais, como teor de carbono, elementos de liga e tamanho de grão. A proposta visa preencher lacunas observadas na literatura e na indústria, aumentando a precisão nos processos de dobramento, permitindo a redução de desvios dimensionais, otimização de projetos e aumento da eficiência industrial.

Palavras-chave: Correção Fator K. Cálculo Numérico. Dobra de Chapas.

¹ Mestrando em Engenharia e Tecnologia de Materiais, Instituto Federal de Educação, Ciência e Tecnologia do Estado do Rio Grande do Sul (IFRS), Caxias do Sul, Rio Grand do Sul, Brasil. E-mail: fabioloyd@gmail.com

² Doutora em Ciência dos Materiais, Universidade Federal do Estado do Rio Grande do Sul (UFRGS), Porto Alegre, Rio Grand do Sul, Brasil. E-mail: lisiane.trevisan@farroupilha.ifrs.edu.br

³ Doutor em Química Orgânica, Universidade de São Paulo (USP), São Paulo, São Paulo, Brasil.
E-mail: paulo.janissek@caxias.ifrs.edu.br

⁴ Doutor em Ciência e Tecnologia dos Materiais, Universidade Federal do Estado do Rio Grande do Sul (UFRGS), Porto Alegre, Rio Grand do Sul, Brasil. E-mail: juliano.toniolo@caxias.ifrs.edu.br

ABSTRACT

Sheet metal bending is a widely employed industrial process in which precise control of parameters such as the K-factor is critical to ensuring dimensional quality and minimizing waste. This article presents a systematic literature review of springback prediction methods and K-factor correction strategies, focusing on studies published between 1995 and 2025. Following an extensive bibliographic search, fifteen peer-reviewed studies were selected based on their relevance and methodological rigor. The predominant approaches identified include finite element method (FEM) simulations, artificial neural networks, multiscale modeling, and experimental techniques—the latter remaining essential for model calibration. The analysis reveals a growing trend toward the use of complex computational techniques, although these are often limited by cost and accessibility. As its main contribution, this study proposes the conceptual foundations for developing a simplified K-factor correction equation based on the physicochemical and microstructural properties of materials, including carbon content, alloying elements, and grain size. The proposed approach aims to address gaps identified in both the literature and industrial practice, enhancing bending process accuracy, reducing dimensional deviations, optimizing design, and improving industrial efficiency.

Keywords: K Factor Correction. Numerical Calculation. Sheet Metal Bending.

RESUMEN

El doblado de chapa metálica es un proceso ampliamente utilizado en la industria, donde el control preciso de parámetros como el factor K es esencial para garantizar la calidad dimensional y minimizar el desperdicio. Este artículo presenta una revisión sistemática de la literatura sobre métodos de predicción de la recuperación elástica y estrategias de corrección del factor K, centrándose en el período de 1995 a 2025. Tras una extensa investigación bibliográfica, se seleccionaron quince estudios para conformar el marco teórico de este artículo, con base en criterios de relevancia, rigor metodológico y revisión por pares. Los métodos predominantes en los estudios revisados incluyen simulaciones de elementos finitos (FEM), redes neuronales artificiales, modelado multiescala y enfoques experimentales, siendo estos últimos relevantes para la calibración de modelos. El análisis revela una tendencia creciente hacia el uso de técnicas computacionales complejas, si bien con limitaciones de costo y accesibilidad. Como contribución, este trabajo propone la base conceptual para desarrollar una ecuación simplificada de corrección del factor K, basada en variables fisicoquímicas y microestructurales de los materiales, como el contenido de carbono, los elementos de aleación y el tamaño de grano. La propuesta busca subsanar las deficiencias observadas en la literatura y la industria, aumentando la precisión de los procesos de plegado, lo que permite reducir las desviaciones dimensionales, optimizar el diseño y aumentar la eficiencia industrial.

Palabras clave: Corrección del Factor K. Cálculo Numérico. Plegado de Chapa Metálica.



Esta obra está bajo una [Licencia Creative Commons Atribución- NoComercial 4.0 Internacional](https://creativecommons.org/licenses/by-nc/4.0/)

INTRODUÇÃO

O dobramento de chapas metálicas é amplamente utilizado em setores como o automotivo, aeroespacial, agrícola e de bens de consumo, sendo essencial para peças com múltiplos planos e geometrias complexas (Groover, 2010). Trata-se de um dos processos de conformação mais recorrentes na manufatura moderna, aplicado tanto em pequenos suportes metálicos quanto em grandes painéis estruturais. Sua relevância para a precisão dimensional e a repetibilidade justifica o número crescente de estudos voltados à sua otimização.

Entre os principais desafios está a determinação do fator K, que define o posicionamento da linha neutra e influencia diretamente o cálculo do comprimento desenvolvido da peça (ASM Handbook, 2005).

Segundo Callister e Rethwisch (2016), o fator K é obtido através da equação:

$$K = \frac{t}{T}$$

onde


K representa o fator seu próprio fator e indica a posição da linha neutra em relação à espessura da chapa; t é a distância da superfície interna da dobra até a linha neutra e T faz menção espessura total da chapa.

O fator K varia, tipicamente, entre 0,30 e 0,50, em função do raio de dobra, da espessura e das propriedades mecânicas, sendo parâmetro essencial para o cálculo do comprimento desenvolvido (Callister e Rethwisch, 2016). Tradicionalmente, é obtido por tabelas empíricas elaboradas a partir de observações práticas, que desconsideram fatores como composição química e microestrutura. Estudos recentes mostram que essas variáveis afetam significativamente a deformação, revelando limitações dos métodos tradicionais. Nesse contexto, pesquisas como Liu *et al.* (2021) e Wang *et al.* (2024) propõem o uso de redes neurais e modelagem multiescala para incorporar variáveis microestruturais e aprimorar a predição do fator K.

A aplicação de cálculos numéricos e simulações também tem se mostrado promissora, oferecendo ajustes mais precisos e auxiliando no projeto de matrizes e cunhos. Abordagens baseadas em elementos finitos e inteligência artificial ampliam a previsibilidade e reduzem problemas como o retorno elástico (springback), que compromete a precisão dimensional (Liu *et*

al., 2021). O springback, segundo Callister e Rethwisch (2016), decorre da recuperação elástica após a remoção da carga, quando parte da tensão armazenada no material é liberada, levando a uma leve recuperação da geometria original, conforme ilustrado na Figura 1.

Figura 1. Representação esquemática do fenômeno de retorno elástico (springback) em processos de dobramento de chapas metálicas.



Fonte: Artizono. Disponível em: <https://artizono.com/pt/retorno-elastico-na-dobragem-de-chapas-metalicas/>. Acesso em 20 março de 2025.

Uma abordagem interessante do uso de métodos numéricos é apresentada para compósitos bimetálicos, onde a adição de ligas intermediárias pode melhorar a ligação entre aços austeníticos e ferríticos, reforçando a relevância de entender as interações em nível atômico para otimizar o desempenho mecânico em processos de conformação (He *et al.*, 2021).

Dametew e Gebresenbet (2016) investigaram o efeito do springback no dobramento de chapas metálicas, considerando espessura, geometria das ferramentas, atrito e propriedades do material. Utilizando o ANSYS LS-DYNA, simularam alumínio, cobre, aços de baixo carbono e de alta resistência, comprovando que o controle dessas variáveis é essencial para garantir tolerâncias. O estudo reforça a necessidade de otimizar as condições de dobra e aponta para a obtenção de equações de correção do fator K que considerem variações de material e processo.

O uso de redes neurais profundas também tem se mostrado promissor. Liu *et al.* (2021) integraram mecânica dos materiais e modelos de aprendizado, otimizando a relação entre parâmetros de dobra e deformações, aumentando a precisão na predição do springback e contribuindo para o refinamento do fator K.

Fu *et al.* (2013) analisaram a modelagem analítica e a simulação numérica no processo de dobra com três rolos em chapas metálicas de grande porte. Utilizando o Abaqus, verificaram consistência entre resultados analíticos, numéricos e experimentais, demonstrando eficácia na previsão do springback e reforçando a utilidade da abordagem para o fator K. De forma semelhante, Gattmah *et al.* (2019) aplicaram o método dos elementos finitos para prever tensões residuais e retorno elástico, concluindo que variáveis como raio do punção e espessura da chapa

impactam diretamente a precisão dimensional.

Estudos recentes também avançaram em frentes complementares. Pieper e Mahendran (2023) propuseram um modelo numérico para chapas corrugadas sob cargas estáticas, incluindo equações de projeto que consideram parâmetros geométricos e microestruturais. Wang *et al.* (2023) mostraram que o nitrogênio em aços inoxidáveis 316L(N) melhora a resistência à corrosão e ao escoamento, em linha com a relação Hall-Petch, evidenciando o papel da composição química no fator K. Na mesma direção, Wang *et al.* (2024) usaram modelagem multiescala para avaliar a evolução da textura em ligas de alumínio 6063, mostrando que alterações microestruturais afetam a formabilidade e fornecem base para ajustes no fator K. Paul *et al.* (2022) analisaram o aço inoxidável SUS304L com microestrutura bimodal, evidenciando o equilíbrio entre resistência e ductilidade como fator determinante no comportamento durante a conformação.

Apesar dos avanços, o uso de softwares especializados de alto custo ainda limita a aplicação prática dessas abordagens. Persiste a ausência de métodos mais simples e acessíveis, que considerem variáveis composicionais e microestruturais sem depender de recursos computacionais intensivos. Este artigo, portanto, revisa a literatura com foco nessa lacuna, propondo um modelo simplificado de correção do fator K, fundamentado em composição química e microestrutura, capaz de conciliar precisão dimensional e aplicabilidade industrial.

REFERENCIAL TEÓRICO

A produção científica sobre o ajuste do fator K e a previsão do springback em chapas metálicas evidencia uma transição metodológica significativa nas últimas décadas. Para compreender esse avanço, os estudos foram organizados em dois períodos: 1995–2009, com predominância de abordagens experimentais e analíticas, e 2010–2025, quando se intensificou o uso de técnicas computacionais, como o MEF (Método dos Elementos Finitos) e redes neurais artificiais (RNA).

Grande parte dos trabalhos concentra-se em chapas de ligas de alumínio e aços inoxidáveis, revelando ampla variação de métodos. Observa-se uma mudança de paradigma, do uso de tabelas empíricas para simulações e modelagens inteligentes. A incorporação de IA, especialmente redes neurais e MEF, ampliou a precisão dos modelos preditivos de springback. Nesse contexto, a equação clássica do fator K, que relaciona a linha neutra à espessura da chapa

(Callister e Rethwisch, 2016), passou a ser ajustada de forma adaptativa conforme microestrutura e liga metálica. Exemplo disso é Liu *et al.* (2021), que integraram aprendizado profundo a funções físico-matemáticas clássicas para refinar cálculos do fator K.

Período 1995–2009: Aplicações Iniciais de MEF e Redes Neurais

No início dos anos 2000, Wierzbicki e Kotecki (2001) utilizaram o MEF para prever o springback em chapas de alumínio 2014-T6 e 6061-T6, validando seus modelos experimentalmente e destacando a necessidade de incluir anisotropia e microestrutura. Kazan e Tiryaki (2008), por sua vez, aplicaram uma rede neural feedforward treinada com dados de simulações FEA, obtendo boa correlação entre resultados previstos e experimentais, o que demonstrou o potencial do método como alternativa parcial às simulações numéricas completas.

Período 2010–2025: Integração de IA, Modelagens Numéricas e Variáveis Microestruturais

Com os avanços computacionais, os estudos mais recentes passaram a adotar metodologias híbridas e multiescalares. Trzepieciński e Lemu (2020) propuseram um modelo preditivo do coeficiente de springback (K_s) utilizando uma rede MLP associada a algoritmo genético (GA). As variáveis de entrada incluíram profundidade da punção, largura da chapa, tensão de escoamento e módulo de elasticidade. Embora a equação gerada pela rede neural não tenha sido explicitada de forma algébrica, o modelo foi representado pela seguinte expressão:

$$K_s = f(d, w, \sigma_y, E)$$

onde:

d – Profundidade da punção (punch depth): distância que a ferramenta punção penetra na chapa no processo de dobramento. Essa variável influencia diretamente a deformação plástica e a quantidade de retorno elástico, sendo apontada no estudo com a mais sensível ao springback.

w – Largura da chapa (width): refere-se à dimensão transversal da chapa metálica em relação à direção de dobra. Alterações na largura afetam a distribuição de tensões e a rigidez da peça, impactando a magnitude do retorno elástico.

σ_y – Tensão de escoamento (yield strength): é a tensão mínima necessária para iniciar a deformação plástica permanente no material. Quanto maior esta tensão, maior a tendência de retorno elástico, pois o material

resiste mais à deformação e “retorna” com maior intensidade.

E – Módulo de elasticidade (elastic modulus): representa a rigidez do material na região elástica, sendo a relação entre tensão e deformação antes do escoamento. Um módulo de elasticidade elevado indica um material mais rígido, o que pode aumentar o retorno elástico após a remoção da carga.

Xu *et al.* (2021) aplicaram uma rede BPNN otimizada por GA e PSO para prever o springback em chapas de grande porte de cascos navais. O modelo obteve R^2 superior a 0,98, erro médio abaixo de 2% e tempo de predição inferior a 10 segundos, confirmando a eficiência da inteligência artificial em oferecer predições rápidas e precisas em contextos industriais complexos.

Os estudos revisados evidenciam avanços metodológicos relevantes na predição do retorno elástico e na estimativa do fator K, mostrando que análises por elementos finitos, redes neurais e modelagens analíticas contribuem para maior precisão em variáveis críticas que afetam a qualidade dimensional (Liu *et al.*, 2021; Dametew; Gebresenbet, 2016).

Além disso, observa-se uma tendência crescente de pesquisas que empregam recursos computacionais avançados e, em alguns casos, ampla coleta de dados. A Tabela 1 resume e categoriza os principais métodos identificados nos trabalhos consultados.

Tabela 1. Diagrama de métodos e suas vantagens e limitações.

MÉTODO	DESCRIÇÃO	VANTAGENS	LIMITAÇÕES	REFERÊNCIAS
Empírico	Baseado em tabelas desenvolvidas por observações práticas	Simples e acessível	Sem precisão garantida; tentativa e erro	Método tradicional
Analítico	Equações matemáticas para cálculo do fator K	Mais preciso que o método empírico	Não considera microestrutura	Fu <i>et al.</i> (2013)
Simulação MEF	Análise por elementos finitos para prever deformações e springback	Alta precisão	Alto custo computacional	Dametew & Gebresenbet (2016); Gattman <i>et al.</i> (2019); Wierzbicki & Kotecki (2001); Pieper & Mahendran (2023)
Redes Neurais	Machine learning para prever deformações	Identifica padrões incomuns e complexos	Requer grande volume de dados	Liu <i>et al.</i> (2021); Trzepieciński & Lemu (2020); Xu <i>et al.</i> (2021); Kazan & Tiryaki (2008)
Modelagem Multiescala	Considera microestrutura e textura do material	Maior previsibilidade	Exige modelagem refinada	Wang <i>et al.</i> (2024); He <i>et al.</i> (2021)
Ensaaios experimentais	Testes práticos para calibração e validação de modelos	Alta confiabilidade	Custoso e demorado	Rocha <i>et al.</i> (2022); Faria <i>et al.</i> (2016); Paul <i>et al.</i> (2022); Wang <i>et al.</i> (2023)

Fonte: os autores, 2025

A Tabela 2 apresenta uma comparação entre os principais estudos analisados que utilizaram modelos computacionais para previsão do springback em processos de dobramento de

chapas metálicas. Nela estão detalhados os métodos empregados (como redes neurais artificiais e elementos finitos), os materiais estudados, o tipo de validação adotado (experimental ou por software), bem como as métricas de desempenho, quando reportadas. Essa sistematização visa não apenas evidenciar a crescente sofisticação dos modelos aplicados, mas também fornece uma base objetiva para comparações futuras entre abordagens preditivas, destacando aquelas com maior precisão e aplicabilidade industrial.

Tabela 2. Comparação das métricas de desempenho dos modelos aplicados.

AUTOR / ANO	MÉTODO UTILIZADO	OBSERVAÇÕES
Liu <i>et al.</i> (2021)	Deep Neural Networks + teoria da plasticidade	Alta precisão com integração de mecânica dos materiais e aprendizado profundo (erro médio de 1,24%).
Xu <i>et al.</i> (2021)	BPNN + Algoritmo Genético (GA) + PSO	Tempo de predição < 10 s; modelo robusto aplicado em chapas de grande porte (erro médio inferior a 2%).
Kazan e Tiryaki (2008)	Redes Neurais Feedforward + FEA	Boa correlação qualitativa; sem métricas explícitas reportadas.
Trzepieciński & Lemu (2020)	MLP + Algoritmo Genético	Sem valores numéricos; profundidade da punção como variável sensível.
Fu <i>et al.</i> (2013)	Modelo analítico + Simulação (ABAQUS)	Modelo analítico validado experimentalmente.
Gattmah <i>et al.</i> (2019)	Simulação MEF (FEA)	Predição de tensões e springback; sem métricas publicadas.
Dametew & Gebresenbet (2016)	Simulação MEF (LS-DYNA)	Simulação detalhada de variáveis; sem métricas publicadas.
Pieper & Mahendran (2023)	Modelo numérico + análise estrutural	Modelo numérico aplicado a estruturas corrugadas.
Wang <i>et al.</i> (2024)	Modelagem multiescala + simulação	Integração de microestrutura e textura; sem métricas publicadas.
Paul <i>et al.</i> (2022)	Análise nanomecânica + caracterização microestrutural	Resultados experimentais para resistência e ductilidade.
Wang <i>et al.</i> (2023)	Estudo experimental + análise composicional	Análise do efeito do nitrogênio; resultados experimentais.
He <i>et al.</i> (2021)	Estudo experimental de ligação bimetálica	Estudo da ligação entre aços ferríticos e austeníticos.
Rocha <i>et al.</i> (2022)	Ensaio experimentais (tração, dureza, metalografia)	Caracterização completa de materiais para estampagem profunda.
Faria <i>et al.</i> (2016)	Comparativo experimental (aços C-Mn e inoxidáveis)	Estudo comparativo entre aços para propriedades mecânicas.

Fonte: os autores, 2025.

Importância da Microestrutura e Elementos de liga

Uma limitação dos métodos tradicionais de correção de parâmetros de dobramento é a desconsideração da composição química e de fatores microestruturais, especialmente em ligas complexas como os aços inoxidáveis. Estudos recentes ressaltam que variáveis como tamanho de grão, teor de carbono e adição de elementos como nitrogênio influenciam diretamente a resistência mecânica e a ductilidade (Wang *et al.*, 2023; Paul *et al.*, 2022). A integração dessas

variáveis em equações corretivas é essencial para modelos mais consistentes.

A microestrutura dos aços está ligada à composição química, em especial aos teores de carbono, cromo e níquel, que determinam resistência mecânica e à corrosão (ASM, 1992). Aços austeníticos, como 304 e 316, apresentam estrutura predominantemente austenítica, com elevada ductilidade e boa conformabilidade; o 304L, por ter menor teor de carbono, oferece maior resistência à corrosão intergranular. Já o aço 430, de estrutura ferrítica (CCC), possui propriedades magnéticas e resistência à oxidação em altas temperaturas, mas menor ductilidade em comparação aos aços austeníticos (Colpaert, 2008; Callister; Rethwisch, 2016). Dessa forma, a escolha do material e o controle do processo de conformação são decisivos para previsibilidade e precisão dimensional (Faria *et al.*, 2016).

Colpaert (2008) destaca que a redução de inclusões e o refinamento de grãos são práticas fundamentais para otimizar resistência e tenacidade. O ASM Handbook (1992) também recomenda esse controle microestrutural como forma de garantir maior confiabilidade das chapas nos processos de conformação.

Rocha *et al.* (2022) caracterizaram detalhadamente os aços inoxidáveis AISI 304 (austenítico) e 430 (ferrítico) aplicados à estampagem profunda. As propriedades mecânicas analisadas mostraram diferenças significativas de desempenho, evidenciando a necessidade de dados específicos de cada lote. Ensaio de tração e análises de anisotropia forneceram subsídios para ajustes de ferramentas e redução de custos associados a falhas superficiais e desperdícios de material.

METODOLOGIA

Este estudo caracteriza-se como uma revisão de literatura de caráter exploratório, cujo objetivo foi analisar estudos recentes relacionados ao tema, desenvolvendo e aprimorando conceitos para identificar lacunas que possam subsidiar pesquisas futuras (Botelho; Cruz, 2013).

A metodologia adotada consistiu em buscas sistemáticas em bases de dados consolidadas: ScienceDirect, Google Scholar e Portal de Periódicos da CAPES. Na primeira etapa, utilizaram-se as palavras-chave: “K factor correction metal bending numerical calculation”. Essa busca inicial retornou cerca de dezesseis mil publicações, o que indicou a necessidade de refinamento dos critérios.

Foram então aplicados filtros de período (1995–2025) e idioma (inglês e português),

priorizando estudos que abordassem a determinação do fator K, o fenômeno do springback ou variáveis microestruturais em processos de conformação de chapas metálicas. Para a segunda etapa, ampliou-se a combinação de termos para “K factor springback correction numerical calculation alloying elements microstructural analysis metallurgy thin metal sheets”, o que reduziu o volume de resultados e permitiu análise mais aprofundada. Os resultados das buscas bibliográficas foram organizados em duas rodadas consecutivas, sistematizadas na Tabela 3.

Tabela 3. Resultados relevantes da pesquisa bibliográfica de artigos científicos.

RESULTADOS DA PESQUISA BIBLIOGRÁFICA			
	Science Direct	Google Scholar	Periódicos CAPES
Primeira seleção de palavras-chave	119	16600	23
Segunda seleção de palavras-chave	15	2607	2

Fonte: os autores, 2025

O passo seguinte foi estabelecer um recorte temporal aos resultados, separando-os em dois blocos: 1995 a 2009 e 2010 até 2025, visando observar também a influência do desenvolvimento dos softwares de simulação e do poder computacional empregado nas pesquisas, a fim de obter uma potencial lacuna metodológica que fornecesse uma oportunidade de desenvolvimento de um novo método. Desta maneira é possível sistematizar graficamente os blocos temporais em dois grupos distintos conforme apresentado na Tabela 4.


Tabela 4. Resultado da busca bibliográfica por base e período.

BASE DE DADOS	PERÍODO 1995–2009	PERÍODO 2010–2025	TOTAL DE RESULTADOS
Google Acadêmico	467	2140	2607
ScienceDirect	1	14	15
Periódicos Capes	0	2	2
Total Geral	468	2156	2624

Fonte: os autores, 2025

Com a análise gráfica detalhada, representada nas Figuras 1 e 2, é possível de forma mais clara verificar o expressivo aumento do número de estudos relacionados ao tema deste trabalho com o passar dos anos, destacando a relevância da pesquisa.

Figuras 2 e 3. Representação gráfica do recorte temporal implementado na pesquisa.



Fonte: os autores, 2025.

Devido ao ainda grande número de resultados retornados, se fez necessária uma nova rodada de seleção e classificação dos materiais potencialmente úteis nesta linha de pesquisa.

A triagem dos materiais pesquisados e que serão objeto da revisão bibliográfica a seguir teve auxílio de inteligência artificial (ChatGPT Plus) para filtragem dos resultados amplos fornecidos pelo Google Acadêmico. Importante destacar que o uso desta ferramenta auxiliou apenas na triagem inicial (tendo em vista que esta ainda não atende o rigor metodológico de uma pesquisa científica), removendo duplicações, resultados sem revisão por pares e organizando resultados.

A avaliação metodológica e seleção final dos estudos foram realizadas manualmente pelos autores, priorizando os artigos de melhor correlação e aderência ao tema do estudo, com maior confiabilidade e estrutura metodológica clara. O resultado final de trabalhos potencialmente úteis tem seu resultado expresso na Tabela 5.

Tabela 5. Artigos potencialmente úteis após duas rodadas de busca.

RESULTADO APÓS DUAS RODADAS DE BUSCAS			
Science Direct	Google Scholar	Periódicos CAPES	TOTAL
9	5	1	15

Fonte: os autores, 2025.

RESULTADOS E DISCUSSÃO


Esta seção apresenta a análise crítica da literatura revisada, com foco nas combinações de métodos que permitem reduzir lacunas metodológicas e nas implicações para futuras investigações experimentais. Os dados sistematizados fornecem base para a proposição de um modelo de ajuste do fator K com relevância acadêmica e industrial.

Observa-se forte discrepância entre os blocos temporais: no período de 1995 a 2009 há poucos trabalhos publicados, enquanto entre 2010 e 2025 registra-se expressivo crescimento. Esse aumento relaciona-se ao avanço das ferramentas de simulação, do uso de inteligência artificial e da maior disponibilidade de bases acadêmicas, refletindo o interesse crescente em aprimorar a previsão do springback e a influência da microestrutura e composição no fator K.

A análise revela uma transformação metodológica clara. Até 2009 prevaleceram abordagens empíricas e analíticas, baseadas em fórmulas geométricas aplicadas a ligas padronizadas, com apenas dois estudos empregando simulação por MEF. Após 2010, expandiu-se o uso de inteligência artificial e métodos híbridos: quatro estudos aplicaram redes neurais, dois deles combinados a algoritmos genéticos (Trzepieciński & Lemu, 2020; Xu *et al.*, 2021). Três pesquisas também incorporaram ensaios experimentais para validar modelos computacionais.

Destaca-se, contudo, que oito dos 15 estudos (mais da metade) não empregaram MEF, IA ou validações experimentais, baseando-se apenas em ajustes empíricos ou simulações simplificadas. Essa limitação reforça a persistência de práticas pouco integradas à microestrutura do material. A Figura 4 sintetiza e representa as interseções entre os principais métodos identificados.

Figura 4. Interseções entre três métodos (MEF, Redes Neurais e Experimental).



Fonte: os autores, 2025.

A combinação mais frequente foi a de IA com métodos experimentais (2 estudos) seguida por MEF com IA (1 estudo) e MEF com experimentação (1 estudo). Apenas um estudo empregou as três abordagens de forma simultânea para análise do mesmo problema. Essa baixa sobreposição revela que o uso combinado de métodos sofisticados ainda é restrito, provavelmente em razão de custos operacionais, limitações de infraestrutura e carência de domínio técnico nas empresas.

Outro ponto crítico identificado foi a ausência de modelos que incorporem variáveis físico-químicas ou microestruturais no cálculo do fator K. Nenhum dos estudos propôs uma equação que relacione parâmetros como teor de carbono, fração de fase ou tamanho de grão ao deslocamento da linha neutra durante a dobra, embora algumas publicações (como Wang *et al.*, 2024; Paul *et al.*, 2022) já apontem, de forma indireta, a influência desses fatores sobre a conformabilidade do material.

Essas constatações evidenciam a necessidade de um modelo que una simplicidade operacional, aplicabilidade prática e embasamento científico. A proposta aqui delineada busca preencher justamente essa lacuna, ao integrar dados metalográficos e composicionais - frequentemente disponíveis em laudos técnicos - para estimar o fator K com maior aderência às propriedades reais do material.

Em síntese, os resultados desta revisão evidenciam não apenas a trajetória metodológica já consolidada, mas também os domínios que permanecem insuficientemente explorados. A constatação de que mais de 50% dos estudos revisados desconsideram variáveis físico-químicas

revela uma lacuna metodológica concreta, cuja superação é essencial para aprimorar a previsibilidade e a precisão dos processos de dobramento.

Proposição Metodológica de um Modelo de Correção

Nesse contexto, o modelo conceitual proposto neste trabalho, fundamentado na utilização de dados provenientes de espectrometria de fluorescência de raios X (FRX), caracterização microestrutural e propriedades mecânicas, busca reduzir a dependência de abordagens empíricas genéricas, limitadas em termos de acurácia, e estabelecer as bases para um método mais robusto, adaptável e tecnicamente sustentado.

Ao incorporar como variáveis-chave a composição química (teor de carbono e proporção de elementos de liga) e aspectos microestruturais, se objetiva oferecer um procedimento simplificado, porém consistente, para ajuste do fator K em processos de dobra. Essa estratégia visa direcionar ao método numérico tradicional uma abordagem integrada e simplificada, capaz de melhorar a previsibilidade dimensional sem recorrer, necessariamente, a recursos computacionais de alto custo ou a modelos complexos baseados em inteligência artificial, conciliando viabilidade prática e rigor científico.

De forma preliminar, o fator K pode ser expresso como uma função dependente de variáveis físico-químicas e microestruturais, bem como de propriedades mecânicas obtidas experimentalmente. Assim, a equação de correção do fator K é uma função das variáveis-chave citadas no parágrafo anterior (e possivelmente de outras variáveis microestruturais ou mecânicas), e pode ser genericamente expressa como:

$$K = f(C, Ei, dg, \sigma_y, E, \dots)$$

onde

C representa o teor de carbono da liga; *Ei* corresponde ao percentual de elementos de liga (como Cr, Ni, Mo, entre outros); *dg* indica o tamanho médio de grão; σ_y refere-se à tensão de escoamento; e *E* ao módulo de elasticidade. Outras variáveis provenientes de ensaios mecânicos poderão ser incorporadas em etapas posteriores, a depender de sua relevância para a resposta do material ao processo de conformação.

A formulação proposta neste artigo ainda não decorre de dados experimentais consistentes para estabelecer uma relação algébrica com o rigor desejado. No entanto, esta visualização é importante pois permite estabelecer as bases conceituais da equação de ajuste do fator K. Após a definição dos coeficientes, esta equação possibilitará que a correção do fator K não se restrinja a tabelas empíricas, mas que seja fundamentada em características intrínsecas do material, permitindo maior precisão e previsibilidade nos processos de dobra.

Desafios Sobre os Avanços Tecnológicos

Embora métodos baseados em simulações numéricas e inteligência artificial tenham se mostrado eficazes na predição de parâmetros de dobra, como nos trabalhos de Fu *et al.* (2013) e Gattmah *et al.* (2019), sua aplicação em larga escala ainda enfrenta desafios, principalmente devido ao custo computacional e à complexidade de implementação. Pesquisas com redes neurais profundas (Liu *et al.*, 2021) reforçam o potencial dessas técnicas, mas exigem grandes volumes de dados para treinamento, o que limita sua adoção por pequenas e médias indústrias.

Nesse cenário, métodos simplificados baseados em características dos materiais surgem como alternativa viável para processos que demandam soluções acessíveis e de fácil aplicação. Além disso, estudos como os de Pieper e Mahendran (2023) e Wang *et al.* (2024) demonstram que a inclusão de parâmetros geométricos e microestruturais nas modelagens aumenta a previsibilidade e a estabilidade do processo de dobra.

Por fim, a revisão indica tendência das pesquisas em direção a abordagens baseadas em grandes bases de dados e softwares especializados. A Tabela 6 resume e classifica as metodologias identificadas, oferecendo um panorama das estratégias mais empregadas.

Tabela 6. Correlação entre os diferentes métodos adotados nos trabalhos considerados na pesquisa bibliográfica.

MÉTODO	OCORRÊNCIAS EM ESTUDOS DIRETAMENTE RELEVANTES
Analítico	1
Simulação MEF	2
Redes Neurais	4
Modelagem Multiescala	1
Ensaio experimentais	3
Mais de um método implementado	4
TOTAL	15

Fonte: os autores, 2025

Aplicabilidade Industrial e Perspectivas Futuras

Os resultados revisados sugerem que métodos menos dependentes de recursos computacionais avançados podem fornecer uma base teórica sólida para estudos futuros e, ao mesmo tempo, atender às demandas práticas da indústria. Trabalhos como os de He *et al.* (2021) evidenciam que a incorporação de variáveis microestruturais permite maior precisão nos cálculos e amplia os limites de desempenho mecânico em ligas metálicas.

A redução da dependência de softwares complexos proposta neste estudo pode democratizar o acesso a tecnologias de otimização de processos, beneficiando indústrias com restrições de investimento em P&D. Nesse sentido, destaca-se a necessidade de explorar métodos numéricos simplificados, como uma equação de ajuste de parâmetros de dobra, complementados por possíveis validações teóricas ou simulações.

Para tanto, delineia-se uma etapa experimental futura, visando validar uma equação que relacione diretamente variáveis materiais e parâmetros de dobra. Essa validação experimental, abordada com detalhes adiante, fornecerá dados robustos para a criação de um método simplificado, tecnicamente consistente e aplicável em diferentes contextos produtivos.

Diferentemente das abordagens que dependem de simulações intensivas ou de grandes volumes de dados, este estudo propõe um modelo simplificado, fundamentado em variáveis físico-químicas e microestruturais, capaz de oferecer soluções acessíveis e eficientes à indústria.

Etapa Experimental Proposta

A lacuna entre os modelos altamente sofisticados e os empíricos convencionais revela uma oportunidade para o desenvolvimento de uma abordagem intermediária, baseada em dados físico-químicos e metalúrgicos dos materiais, porém de aplicação direta.

A proposta deste trabalho, portanto, se fundamenta na construção de uma equação de correção do fator K que incorpore variáveis como teor de carbono, proporção de elementos de liga (como Cr, Ni), e características microestruturais (tamanho de grão, por exemplo). Essas variáveis serão quantificadas por meio de ensaios experimentais, conforme abordado logo adiante.

A adoção de três tipos de aço (SAE 304, 304L e 1020) com diferentes teores de carbono e composições químicas permitirá uma análise comparativa robusta e representativa. Por meio da

espectrometria e da análise microestrutural via MEV, será possível observar como pequenas variações na composição interferem nas propriedades mecânicas (avaliadas por tração e microdureza) e, conseqüentemente, nos parâmetros de dobra.

Com base nos achados da literatura e nas lacunas identificadas, propõe-se a realização de uma etapa experimental futura com o objetivo de validar a aplicação prática de uma equação de correção do fator K a partir de variáveis composicionais e microestruturais. O plano experimental abrange ensaios quanto à composição química e teor de carbono, conforme demonstrado na Tabela 7, com os respectivos objetivos para o uso de cada um deles.

Tabela 7. Planejamento experimental com materiais e número de amostras.

MATERIAL	CLASSIFICAÇÃO	NÚMERO DE AMOSTRAS	OBJETIVO
SAE 304	Aço inoxidável austenítico	5 (mais 3 reservas)	Avaliar impacto de Cr e Ni na microestrutura e <i>springback</i>
SAE 304L	Aço inoxidável austenítico (baixo C)	5 (mais 3 reservas)	Comparar efeito do menor teor de carbono
SAE 1020	Aço carbono	5 (mais 3 reservas)	Observar comportamento com menor quantidade de elementos de liga

Fonte: os autores, 2025.

Para caracterização dos materiais e validação da relação entre composição, microestrutura e comportamento mecânico, ensaios estão previstos para fornecer base sólida e robusta à etapa experimental, conforme apresentado na Tabela 8.

Tabela 8. Ensaios previstos e locais de execução.

ENSAIO	OBJETIVO
Espectrometria	Identificação da composição química (C, Cr, Ni, Mn, etc.)
Metalografia com Microscopia Eletrônica de Varredura (MEV)	Verificação microestrutural e morfologia dos grãos
Ensaio de microdureza Vickers	Avaliação da resistência localizada e correlação com estrutura metalúrgica
Ensaio de tração	Determinação de propriedades mecânicas: σ_y , E , alongamento

Fonte: os autores, 2025

A escolha dos materiais baseou-se em suas diferenças de composição química (especialmente elementos de liga e percentual de carbono) e estrutura cristalina, conforme discutido na revisão de literatura. A análise por MEV permitirá caracterizar os materiais e correlacionar o tamanho de grão e morfologia com o esperado para cada caso. A espectrometria e os ensaios mecânicos permitirão quantificar as variáveis de entrada para o desenvolvimento de uma equação simplificada de ajuste do fator K, a ser proposta futuramente.

CONCLUSÃO

Este estudo apresentou uma revisão sistemática e crítica da literatura sobre métodos de correção de parâmetros no dobramento de chapas metálicas, evidenciando a evolução das abordagens metodológicas entre 1995 e 2025. Observou-se que, embora técnicas baseadas em inteligência artificial e simulação computacional avancem em precisão, sua adoção industrial ainda é limitada por custos e complexidade, ao passo que métodos empíricos tradicionais carecem de fundamentação em variáveis críticas, como composição química e microestrutura.

A análise da bibliografia revelou que a maioria dos estudos ainda se baseia em abordagens empíricas ou simplificadas, com 7 trabalhos incorporando técnicas como MEF, inteligência artificial ou ensaios experimentais. Além disso, foi evidenciada a ausência de modelos que integrem variáveis físico-químicas e microestruturais, como composição química e características da microestrutura, na predição do fator K.

Com base nessas lacunas, foi proposto um modelo alternativo de baixo custo computacional, fundamentado nas propriedades dos materiais, que podem ser obtidas a partir de espectrometria de FRX e metalografia, visando estimativas mais ajustadas e robustas do fator K. O modelo representa uma contribuição original ao campo, permitindo equilibrar viabilidade prática e rigor técnico, especialmente para aplicação em ambientes industriais com restrição de recursos computacionais.

Os resultados aqui discutidos estabelecem um caminho claro para validações futuras. Deve ser destacada a necessidade de testes experimentais com ligas metálicas distintas, para validar a acurácia e sensibilidade do modelo.

Conclui-se, portanto, que há espaço significativo para evolução nos métodos de predição do fator K, e que a adoção de abordagens mais integradas com a ciência dos materiais pode representar um salto qualitativo importante para a precisão e previsibilidade nos processos de conformação metálica.

REFERÊNCIAS

ASM INTERNATIONAL. **ASM Handbook: Metallography and Microstructures**. v.9. Materials Park, OH: ASM International, 1992.

ASM INTERNATIONAL. **ASM Handbook, Volume 14: Forming and Forging**. Materials Park, OH: ASM International, 2005.

BOTELHO, Joacy Machado; CRUZ, Vilma Aparecida Gimenes da. **Metodologia científica**. São Paulo: Pearson Education do Brasil, 2013.

CALLISTER, William, D. RETHWISCH, David G. **Ciência e engenharia de materiais: uma introdução**; tradução Sergio Murilo Stamile Soares. 9. ed. LTC, Rio de Janeiro, 2016.

COLPAERT, H. **Metalografia dos Produtos Siderúrgicos Comuns**. 4ª edição revista e atualizada por André Luiz V. da Costa e Silva. Editora Blucher, São Paulo, 2008.

DAMETEW, A. W.; GEBRESENBET, T. Numerical investigation of spring back on sheet metal bending process. **Global Journal of Researches in Engineering: A Mechanical and Mechanics Engineering**, v. 16, n. 4, p. 32-54, 2016. Disponível em: <https://globaljournals.org>. Acesso em: 15 out. 2024.

FARIA, G. L. de; GODEFROID, L. B.; ALVES, J. O. Estudo comparativo de propriedades mecânicas de chapas expandidas de aços C-Mn e inoxidáveis. **Tecnologia em Metalurgia, Materiais e Mineração**, São Paulo, v. 13, n. 3, p. 216-223, jul./set. 2016.

FU, Z.; TIAN, X.; CHEN, W.; HU, B.; YAO, X. Analytical modeling and numerical simulation for three-roll bending forming of sheet metal. **The International Journal of Advanced Manufacturing Technology**, v. 69, p. 1639–1647, 2013.

GATTMAN, J.; OZTURK, F.; ORHAN, S. Numerical Simulation of Bending Process for Steel Plate Using Finite Element Analysis. **Arabian Journal for Science and Engineering**, 2019. Disponível em: <https://doi.org/10.1007/s13369-019-04119-8>. Acesso em: 15 out. 2024.

GROOVER, M. P. **Fundamentals of Modern Manufacturing: Materials, Processes, and Systems**. 6th ed. Hoboken: Wiley, 2015.

HE, C.; PAN, G.; XIE, L.; PENG, Q. Enhancement of Diffusion Assisted Bonding of the Bimetal Composite of Austenitic/Ferric Steels via Intrinsic Interlayers. **Materials**, v. 14, n. 9, p. 2416, 2021. Disponível em: <https://doi.org/10.3390/ma14092416>. Acesso em: 14 out. 2024.

KAZAN, R.; TIRYAKI, M. Prediction of *springback* in wipe bending process of aluminum sheets using artificial neural network. **Journal of Materials Processing Technology**, v. 204, p. 392–399, 2008.

LIU, S.; XIA, Y.; SHI, Z.; YU, H.; LI, Z.; LIN, J. Deep learning in sheet metal bending with a novel theory-guided deep neural network. **IEEE/CAA Journal of Automatica Sinica**, v. 8, n. 3, p. 565–581, mar. 2021.

PAUL, Viola; WANG, Yanxu; AMEYAMA, Kei; OTA-KAWABATA, Mie; OHMURA, Takahito. Nanomechanical analysis of SUS304L stainless steel with bimodal distribution in grain size. **Materials Transactions**, v. 63, n. 4, p. 545-554, 2022.

PIEPER, L.; MAHENDRAN, M. Numerical investigation and design of crest-fixed corrugated steel claddings under static wind uplift loading. **Thin-Walled Structures**, v. 182, parte B, p. 110270, 2023.

ROCHA, R. P. da; RIFFEL, M. H.; ROSIAK, A.; SCHAEFFER, L. Caracterização dos aços inoxidáveis AISI 304 e AISI 430 para aplicação em processos de estampagem profunda. **Brazilian Journal of Development**, v. 8, n. 7, p. 51077-51101. Curitiba, jul. 2022. Instituição: Universidade Federal do Rio Grande do Sul (UFRGS).

TRZEPIECIŃSKI, T.; LEMU, H. G. Improving prediction of *springback* in air bending process using artificial neural network and genetic algorithm. **Applied Sciences**, v. 10, n. 14, p. 4911, 2020.

WANG, M.; WU, J.; QIAN, Z.; WU, W.; YANG, Z.; LIU, L.; WANG, H. Texture and bendability evolution mechanism of 6063 aluminum alloy tube formed by free-bending technology employing cross-scale numerical modeling. **Journal of Materials Processing Technology**, v. 332, p. 118568, 2024.

WANG, Y.; WANG, Z.; WANG, W.; BINGYANG, M. Effect of nitrogen content on mechanical properties of 316L(N) austenitic stainless steel. **Materials Science & Engineering A**, v. 884, p. 145549, 2023.

WIERZBICKI, T.; KOTECKI, D. Finite element analysis of *springback* in bending of aluminum alloy sheets. **Archives of Civil and Mechanical Engineering**, v. 3, n. 2, p. 75–83, 2001.

XU, X. *et al.* Prediction of *springback* in hull plates using GA-BPNN + PSO. **Journal of Marine Science and Engineering**, v. 9, n. 6, p. 587, 2021.