

Predição de Deformação e Ruptura para Chapas de Aço A36 sob *Blast Loading*: uma abordagem integrando calibração experimental, Redes Neurais e Amostragem Adaptativa

Vitor H. F. Bettio¹, Cláudio M. D. Peixoto¹, Anselmo S. Augusto¹, José A. F. F. Rocco¹, Girum Urgessa², Fausto B. Mendonça¹ e Lamartine Nogueira Frutuoso Guimarães¹

¹Instituto Tecnológico de Aeronáutica (ITA), São José dos Campos/SP - Brasil

²Howard University, Washington/DC - EUA

Resumo—O dimensionamento estrutural contra eventos de *Blast Loading* esbarra em dois gargalos fundamentais: o alto custo logístico de ensaios em arena e o elevado tempo de processamento de simulações numéricas não-lineares explícitas. Embora a literatura apresente campanhas experimentais calibradas, investigar o limite exato de ruptura de uma chapa de forma empírica requer repetidas detonações por tentativa e erro. Este artigo propõe a integração de Redes Neurais do tipo *Multilayer Perceptron* (MLP) ao Método dos Elementos Finitos (MEF), ancorado em ensaios de campo, não apenas para atuar como um modelo substituto de baixo custo computacional, mas para descobrir ativamente a fronteira de fratura do aço A36 e propor arranjos ótimos para ensaios futuros. A validação cruzada apontou alta precisão das Redes, reduzindo o tempo de inferência para a escala de milissegundos.

Palavras-Chave—*Blast Loading*, Redes Neurais, Aço A36.

I. INTRODUÇÃO

Projetar estruturas de proteção contra detonações é um pilar da engenharia de defesa. A resposta dinâmica de metais dúcteis sob altas taxas de deformação envolve não-linearidades severas. Historicamente, o Método dos Elementos Finitos (MEF) explícito tem sido a ferramenta predominante para essas avaliações. Entretanto, a inclusão de modelos mecânicos cada vez mais complexos, com acúmulo de dano e deleção de elementos, exigem tempos de processamento cada vez maiores, situação incompatível com necessidades de projetos iterativos ou análises rápidas de campo.

Para contornar este gargalo, métodos de Aprendizado de Máquina (*Machine Learning*) têm sido empregados para mapear a física de problemas complexos através de Modelos Substitutos (*Surrogate Models*) [1]. Este artigo desenvolve uma arquitetura de Redes Neurais Artificiais (MLP) [2] capaz de prever quase instantaneamente a resposta de placas de aço A36 ao sopro de cargas esféricas sem invólucro, detonadas ao ar livre.

O diferencial metodológico reside em um *pipeline* iterativo de *Active Learning* [3], adaptado à expansão controlada do banco numérico. O modelo estima sua incerteza e direciona novas simulações às condições mais informativas da fronteira entre integridade e ruptura, concentrando dados no limiar elasto-plástico e reduzindo o custo computacional.

V. Bettio, vitor.bettio@ita.br; C. Peixoto, claudio@ita.br; A. Augusto, anselmo@ita.br; J. Rocco, friz@ita.br; G. Urgessa, girum.urgessa@howard.edu; F. Mendonça, fausto@ita.br; L. N. F. Guimarães, lamar.guima@gmail.com.

II. MODELAGEM NUMÉRICA

A. Calibração Experimental

O modelo numérico tridimensional no solver *Abaqus/Explicit* [4] teve a sua topologia, discretização de malha e interação calibradas com base nos ensaios de campo de Augusto et al. [5]. Nesses testes, chapas de aço A36 com 2,14 mm de espessura foram submetidas a detonações em campo aberto utilizando cargas reais de 334 g do explosivo *Composition B*.

A resposta elasto-plástica e as flechas máximas obtidas na simulação replicaram o comportamento físico do aço com alta fidelidade quando comparadas aos dados empíricos [5], o que validou os parâmetros numéricos de contorno e estabeleceu um *Ground Truth* de alta confiabilidade. A partir dessa calibração, o estudo de referência [5] implementou uma rotina automatizada em Python para expandir o espaço paramétrico, executando 460 simulações dinâmicas explícitas que varreram 10 espessuras comerciais distintas de chapa e 46 variações de distância de afastamento (*stand-off distances*). Considerando todas essas 460 simulações, o custo computacional total consumido foi de aproximadamente 26 horas. Este mapeamento gerou um banco de dados robusto, alicerce inicial para o treinamento da arquitetura bifurcada proposta.

B. Modelo Constitutivo, Falha e Regularização de Malha

A interação da onda de choque com o painel metálico dispensou formulações Eulerianas puras de alto custo computacional, utilizando, em vez disso, o modelo semi-empírico *Conventional Weapons Effects Program* (CONWEP), fundamentado nas equações consolidadas de *Kingery-Bulmash* [6] para imposição direta de perfis de pressão decorrentes de detonações ao ar livre. O material do alvo (Aço ASTM A36) foi modelado com o critério de escoamento de *Johnson-Cook* [7], o qual incorpora o ganho de rigidez por altas taxas de deformação (*strain-rate hardening*), prevenindo deflexões exageradas típicas de parâmetros estáticos. Para a fratura, a iniciação de dano adotou os parâmetros fenomenológicos do mesmo modelo [7], cujo termo de triaxialidade ($D_3 < 0$) garante a redução da ductilidade sob tração multiaxial severa [8], [9].

Uma vez que as simulações do banco de dados de Augusto et al. mapearam o domínio de deflexão elasto-plástica




Fig. 1. Fluxograma da metodologia de geração de dados, amostragem adaptativa e treinamento dos modelos MLP.

contínua, mas não contemplaram o regime extremo de fratura catastrófica do material, o presente estudo avançou ao incorporar um parâmetro de dano (*Damage Evolution*) que governa a exclusão de malha (*Element Deletion*). Essa alteração metodológica é exatamente o que fornece os cenários limítrofes necessários para que a MLP Classificadora e o *pipeline* de *Active Learning* busquem a fronteira de ruptura da chapa.

Para regularizar a dissipação de energia durante a fratura e atenuar a instabilidade por dependência da malha numérica (*Mesh Dependency*), o modelo de evolução de dano foi formulado com base no comprimento característico do elemento, seguindo a regularização proposta por Hillerborg et al. [10]. O domínio estrutural foi discretizado com elementos de casca S4R (*Shell*) de dimensões 10×10 mm. Adotou-se um deslocamento plástico efetivo à falha (u_f) de 0.0025 m com decaimento linear, valor alinhado aos limiares de energia de fratura dúctil (G_f) reportados na literatura para chapas de aço doce sujeitas a altas taxas de deformação [8], [9].

III. METODOLOGIA

A. Espaço Paramétrico e Automação

O espaço de projeto paramétrico foi delimitado para abranger cenários operacionais realistas: massa equivalente de TNT de 0.1 a 5.0 kg; distância de detonação (D) entre 0.1 e 3.0 m; e espessura da chapa entre 1.0 e 8.0 mm. O processo de submissão e extração de resultados cinemáticos foi integralmente automatizado via *scripts* em Python, interfaceando diretamente com a *Application Programming Interface* (API) do Abaqus.

B. Amostragem Adaptativa e Fluxograma Metodológico

A metodologia adotada combinou uma etapa inicial de exploração global com uma fase posterior de refinamento orientado pelo próprio classificador MLP. Inicialmente, foram geradas 1000 simulações por *Latin Hypercube Sampling* (LHS) [11], garantindo uma cobertura ampla e aproximadamente ortogonal do domínio paramétrico. Na modelagem substituta (*Surrogate Modeling*) [12], o LHS atua como um *Design of Experiments* (DoE) estratificado que maximiza a entropia amostral e minimiza a variância dos estimadores estruturais, superando as limitações da amostragem aleatória convencional. Cada cenário simulado é tratado como uma instância ou padrão estruturado composto por um vetor de características preditivas de entrada $\mathbf{x} = [M, e, D]^T$, em que

M denota a massa equivalente de TNT, e a espessura da chapa de aço A36 e D a distância de afastamento (*stand-off distance*).

Em seguida, a MLP classificadora treinada com essa base preliminar avaliou perfis virtuais adicionais e direcionou a seleção de 500 pontos próximos à fronteira de decisão, concentrando novas simulações na região de maior interesse físico: o limiar de rompimento, definido por probabilidades estimadas de falha entre 45% e 80%. Esse procedimento (sumarizado na Fig. 1) caracteriza uma amostragem adaptativa pautada no conceito de *Active Learning* por amostragem de incerteza (*uncertainty sampling*), pois desloca o esforço computacional para os casos mais informativos da transição entre integridade estrutural e ruptura, maximizando o ganho de informação marginal a cada consulta ao modelo de elementos finitos.

C. Amostragem Adaptativa Iterativa

A geração do *Ground Truth* numérico operou em três estágios para mitigar o desbalanceamento das classes estruturais, um obstáculo recorrente em problemas de *Blast Loading* no qual o evento de falha catastrófica compõe a minoria estatística do domínio, induzindo vieses indesejados em algoritmos passivos:

- **Fase 1 (Amostragem Cega):** Geração de 1000 cenários através de *Latin Hypercube Sampling* (LHS) para exploração ortogonal do domínio paramétrico e mapeamento da distribuição conjunta preliminar.
- **Fase 2 (Fronteira Larga):** Treinamento de um classificador preliminar avaliando 500.000 perfis virtuais. Extraiu-se um subconjunto de 250 casos de incerteza crítica (probabilidade de falha entre 45% e 80%), submetendo-os ao MEF. Esta etapa enriqueceu a minoria estatística, saltando de 90 para 265 o número de rupturas registradas, minimizando a assimetria distribucional.
- **Fase 3 (Fronteira Fina):** Re-treinamento com 1250 casos e nova varredura, filtrando uma banda estreita (incerteza de 47,5% a 52,5%). Outros 250 cenários específicos foram simulados, consolidando um *dataset* final de 1500 instâncias.

O total de rupturas registradas atingiu 327 casos, representando 21,8% da base final. A injeção deliberada destes cenários limítrofes força a MLP a refinar a superfície de decisão.

D. Arquitetura das Redes Neurais (MLP)

Uma única rede não é capaz de otimizar simultaneamente um evento discreto (a 'ruptura') e um contínuo (a 'flecha' - o deslocamento máximo da chapa na deflexão) devido à natureza matemática distinta das tarefas de classificação binária e de regressão não-linear, as quais demandam superfícies de decisão e topologias de saída fundamentalmente diferentes. Portanto, implementou-se uma arquitetura bifurcada composta por duas redes independentes do tipo *Multi-layer Perceptron*:

- 1) **Classificador (Ruptura):** Treinado com o *dataset* completo para julgar a integridade estrutural da placa. A camada de saída utiliza a função logística (*Sigmoid*), parametrizando $P(Y = 1 | \mathbf{x})$, em que $Y \in \{0, 1\}$ indica integridade (0) ou falha estrutural (1), e $\mathbf{x} = [M, e, D]^T$ é o vetor paramétrico de entrada. Logo, o classificador estima a probabilidade de falha estrutural para um dado cenário. A otimização minimiza a entropia cruzada binária (*Binary Cross-Entropy Loss*). Mesmo um rasgo parcial da chapa é contabilizado como ruptura estrutural.
- 2) **Regressor (Deslocamento):** Treinado exclusivamente com as placas que não romperam, garantindo que o algoritmo aprenda a mecânica da deformação isenta do cenário de elementos ejetados. Esta vertente modela uma função contínua multidimensional por meio da minimização da função de custo do Erro Quadrático Médio (*Mean Squared Error* - MSE) para prever a deflexão máxima (flecha).

Ambas as redes processam os dados de entrada após uma etapa de pré-processamento baseada na padronização via *StandardScaler*, aplicando uma transformação por *score-z* de modo a centralizar a média em zero e fixar a variância unitária ($\mu = 0, \sigma = 1$). Esse procedimento homogeneiza a ordem de magnitude das variáveis [13], prevenindo a dominância artificial de atributos com escalas numéricas discrepantes (ex.: a distância dada em *metros* e a flecha máxima dada em *milímetros*), além de acelerar a convergência estocástica dos modelos.




Fig. 2. Histórico de convergência da função de perda (*Loss*) do modelo classificador para os conjuntos de treinamento e validação.

A arquitetura empírica [128 – 128 – 128] beneficia-se de topologias largas e rasas para dados tabulares físicos: a largura mitiga o subajuste (*underfitting*) mapeando a não-linearidade da ruptura, enquanto a restrição a três camadas previne o sobreajuste (*overfitting*) do ruído físico explícito.

A transição utiliza a função de ativação *ReLU* para evitar o desvanecimento do gradiente [2]. A atualização dos pesos foi conduzida pelo otimizador *Adam* [14], conferindo estabilidade numérica diante das severas não-linearidades do regime de *Blast Loading*.

As redes foram treinadas em ambiente Python, utilizando as bibliotecas *Scikit-learn* [13]. Os *datasets* empregados no treinamento foram criados a partir de arquivos *.csv* gerados por *scripts* de pós-processamento após a execução das simulações no *Abaqus*. Ressalta-se que não houve inclusão de métricas físicas intermediárias, como tensões ou deformações plásticas, em nenhum dos modelos, de modo que as previsões foram baseadas exclusivamente nas variáveis paramétricas de entrada e nas respostas finais extraídas das simulações.

Para avaliação preditiva, adotaram-se as métricas Acurácia e *F1-Score* (com valor ideal tendendo a 1,0) para classificação, e o Coeficiente de Determinação (R^2) e o Erro Absoluto Médio (MAE) para regressão. Como *baseline* comparativo para a MLP, implementaram-se algoritmos clássicos de *Machine Learning*: *Random Forest* (RF) [15], *Support Vector Regression* (SVR) [16] e Regressão Logística, submetidos ao mesmo protocolo de validação.

IV. RESULTADOS E DISCUSSÕES

A. Validação Experimental

Conforme os ensaios experimentais de Augusto et al. [5], no cenário de campo próximo (*near field*), com $Z = 300$ mm, os três ensaios reais indicaram deformação máxima de 66 mm. Para esse mesmo cenário, o modelo de simulação no *Abaqus* utilizado no treinamento, com *mesh size* de 10 mm, apresentou erro aproximado de 1%, reforçando a fidelidade da calibração numérica na condição mais crítica avaliada. Sob a ótica do aprendizado de máquina, essa aderência inicial atesta que os dados gerados via MEF constituem um ecossistema de *Ground Truth* estatisticamente consistente, permitindo que os modelos substitutos generalizem de forma fiel a distribuição de probabilidade subjacente ao fenômeno físico.

Aliado a isso, ao contrário de formulações que permitem elongações irreais sob altas pressões, a adoção de *Damage Evolution* assegura a deleção dos elementos ao atingir a energia de fratura. Estes dois fatores — calibração com baixo erro no cenário do *near field* explosivo e a delimitação explícita para a ruptura — estabelecem um modelo substituto que busca operar no limiar de falha do material.

Reforça-se que para cenários de detonação *far field*, o erro apresentado pela simulação *Abaqus* com o uso do CONWEP é maior (da ordem de 15 a 20% da flecha máxima [5]), porém são cenários onde não é esperada a falha estrutural, regiões nas quais o Aço A36 é menos exigido. Portanto o modelo classificador está ajustado justamente para a região de maior interesse.

B. Desempenho Preditivo e Validação Cruzada

Para aferir a capacidade de generalização e mitigar o risco de *overfitting*, os modelos foram avaliados sob o protocolo *K-Fold Cross-Validation* (com $K = 10$ partições), com os dados normalizados isoladamente a cada iteração. Embora a validação no *dataset* final incorpore o viés de seleção (*data leakage*) inerente à amostragem adaptativa iterativa, ela reflete

o desempenho da rede justamente nos cenários de fronteira do evento de ruptura.

O **Modelo Classificador** (particionado e estratificado) apresentou expressiva capacidade preditiva, atingindo Acurácia Média de 96,87% e um *F1-Score* de 92,36% ($\pm 4,38\%$). A consistência destas métricas atesta a eficácia da amostragem iterativa na definição do limiar de ruptura pesquisado para o Aço A36. O aprendizado da rede é fundamentado por sua curva de convergência (Fig. 2), na qual se observa o decaimento da função de custo por entropia cruzada binária. Observa-se que a introdução das instâncias de fronteira (Fases 2 e 3) induz repiques na função *Loss*, refletindo a injeção deliberada de incerteza física na zona de iminência da ruptura, exigindo da MLP uma superfície de decisão topologicamente mais complexa.




Fig. 3. Matriz confusão agregada para a totalidade do conjunto de dados do modelo classificador.

A matriz agregada de 1500 instâncias (Fig. 3) registrou apenas 4 Falsos Positivos e 23 Falsos Negativos. A concentração residual desses erros é um artefato esperado do *Active Learning*, que amostrou deliberadamente a zona de maior incerteza. Ainda assim, o elevado *F1-Score* atesta que o método mitigou o desbalanceamento original, buscando uma alta sensibilidade na detecção de rupturas.

No regime elasto-plástico, o ganho de fidelidade do **Modelo Regressor** foi proeminente. A rede alcançou um Coeficiente de Determinação (R^2) de 0,9955 ($\pm 0,0018$), evidenciando elevada aderência entre os deslocamentos previstos e os valores de referência (Fig. 4). O desvio-padrão extremamente reduzido indica uma variância estrutural desprezível entre os diferentes *folds*.




Fig. 4. Coeficiente de determinação do modelo regressor, com $R^2 = 0,9955$, indicando alta aderência entre valores previstos e simulados.

Essa estabilização computacional é corroborada pelo perfil

de convergência da rede (Fig. 5), cujo decaimento estrito e contínuo da função de custo demonstra a eficiência do otimizador em mapear o domínio elastoplástico contínuo, livre dos ruídos cinemáticos que tipicamente desestabilizam os gradientes em formulações numéricas integradas.




Fig. 5. Histórico de decaimento da função de perda (*Loss*) do modelo regressor, evidenciando a convergência assintótica.

Em comparação com a simulação Abaqus calibrada para o *near field*, a precisão do modelo também é consagrada pelo Erro Absoluto Médio (MAE) de meros 1,60 mm e com variância desprezível, com resíduos distribuídos de forma aleatória e centrada em zero, atestando a ausência de viés preditivo.

C. Interpretabilidade Física do Modelo

Para prover interpretabilidade física da arquitetura proposta, evitando-se um modelo totalmente “caixa-preta” (*black-box*), conduziu-se uma análise de explicabilidade sobre as Redes Neurais treinadas. Utilizou-se a técnica de Importância por Permutação (*Permutation Feature Importance*), implementada via *Scikit-Learn* [13], que mensura o decaimento da acurácia do modelo ao embaralhar iterativamente o ruído de cada variável preditora.

A análise revelou que a distância de afastamento é a variável global predominante para ambas as redes, seguida pela espessura e, surpreendentemente, com importância marginal para a massa de TNT. Esta assimetria reflete a Lei de Escala de Cranz-Hopkinson ($Z = D/M^{1/3}$): como a massa atua sob raiz cúbica, sua influência decai severamente frente à expansão esférica da distância (D^3). Assim, os modelos inferem corretamente a predominância espacial na dinâmica do *blast loading*.

D. Resultados dos Modelos

Os resultados do modelo classificador são representados visualmente nas figuras a seguir. A Fig. 6 sintetiza os pontos de simulação obtidos no *Abaqus*, distinguindo os casos em que a chapa suportou o carregamento, representados em verde, daqueles em que ocorreu rasgamento, representados em vermelho. A curva destacada corresponde ao hiperplano de decisão construído pela MLP classificadora, delimitando a transição entre a região segura e a região de ruptura prevista pelo modelo.

A Fig. 7 apresenta as zonas de segurança e de possível rompimento indicadas pelo classificador ao variar a espessura da chapa. Essa representação permite visualizar como




Fig. 6. Fronteira de decisão do modelo MLP classificador, com pontos de simulação do *Abaqus* em condição segura e em condição de ruptura.




Fig. 8. Comparativo da flecha máxima prevista em função da espessura e da distância escalonada, com massa equivalente de TNT fixada em 2,73 kg.

o aumento da espessura desloca a fronteira de colapso e amplia o domínio operacional seguro, fornecendo um mapa de apoio para seleção de configurações de ensaio e definição de margens de projeto.




Fig. 7. Zonas de segurança e de possível rompimento previstas pelo modelo MLP classificador em função da variação da espessura da chapa.

Para o modelo regressor, foi construída uma visualização tridimensional da flecha máxima em relação à espessura da chapa e à distância escalonada (Fig. 8). Como a visualização direta do espaço completo em quatro dimensões não seria praticável, fixou-se a massa equivalente de TNT no valor médio observado no banco de dados, igual a 2,73 kg. Ainda assim, o hiperplano do modelo regressor pode ser desenhado pela rede MLP para qualquer valor de massa equivalente de TNT dentro do domínio de treinamento. Observa-se também que a superfície prevista apresentou bom ajuste em relação aos dados de simulação do *Abaqus*, indicando coerência entre a resposta contínua aprendida pela MLP e os resultados numéricos de referência.

E. Eficiência Computacional

Sob a ótica do custo, o tempo de processamento explícito, que consumia horas no *Abaqus/Explicit* para centenas de simulações, foi reduzido para frações de milissegundo de tempo de inferência pelo modelo de aprendizado de máquina.

Utilizando os modelos MLPs salvos em arquivos *pickle*, as redes entregaram os resultados em aproximadamente 0,4 ms, desempenho cerca de 80.000 vezes mais rápido quando comparado à simulação no *Abaqus* com o mesmo tamanho de malha (*mesh size*), conforme a análise de custo computacional por tamanho de malha apresentada na Tabela 3 do trabalho de Augusto et al. [5]. Essa aceleração evidencia o potencial do modelo substituto para análises paramétricas e avaliações quase instantâneas de cenários de interesse. Esse ganho de eficiência reflete a transição de um regime de integração numérica de equações diferenciais parciais altamente dispendioso para uma fase de inferência em tempo real (*inference phase*), cuja complexidade algorítmica é reduzida a operações de álgebra linear elementares (multiplicações de matrizes por tensores de pesos fixos), otimizando o tempo de execução.

Com a fronteira de colapso mapeada, o modelo passa a fornecer os arranjos balísticos ideais para que futuras campanhas em arena registrem fraturas com o mínimo de detonações empíricas, otimizando os custos de testes.

F. Comparação com Outros Modelos Substitutos

Para validar a escolha da arquitetura MLP bifurcada, realizou-se uma análise comparativa com outros algoritmos clássicos de Aprendizado de Máquina frequentemente empregados como modelos substitutos (*Surrogate Models*) na literatura [12]. Foram avaliados os algoritmos *Random Forest* (RF) [15], *Support Vector Regression* (SVR) [16] e Regressão Logística, submetidos ao mesmo protocolo de Validação Cruzada *K-Fold* ($K = 10$).

Os resultados (Tabela 1) demonstram a superioridade da MLP. No regime elasto-plástico, a MLP atingiu R^2 de 0,9955, superando SVR (0,8620) e RF (0,9750). Seu MAE (1,60 mm) é menos da metade do erro da RF, evidenciando que superfícies *piecewise* falham em capturar o gradiente contínuo da deformação. Na classificação de ruptura, a MLP ($F1 = 0,9236$) também superou a Regressão Logística (0,6720) e a RF (0,8294), confirmando sua capacidade de modelar a fronteira caótica de falha.

Esses resultados apontam que a MLP, aliada à estratégia de *Active Learning*, não apenas maximiza a acurácia global, mas

TABELA 1.
COMPARATIVO DE DESEMPENHO DOS MODELOS.

MODELOS REGRESSORES		
Algoritmo	R ² (K-Fold)	MAE (mm)
SVR (Kernel RBF)	0,8620	8,9626
Random Forest (RF)	0,9750	3,2844
MLP (Proposto)	0,9955	1,6045
MODELOS CLASSIFICADORES		
Algoritmo	Acurácia (K-Fold)	F1-Score (K-Fold)
Regressão Logística	0,8620	0,6720
Random Forest (RF)	0,9313	0,8294
MLP (Proposto)	0,9687	0,9236

Obs.: RF configurado com 100 estimadores, e SVR com kernel radial rbf.

oferece uma estabilidade para mapear as não-linearidades do fenômeno em estudo.

V. CONCLUSÕES

Este trabalho aponta para a eficiência de métodos de amostragem adaptativa aplicados à dinâmica não-linear de materiais, a partir de um estudo de caso com chapas de aço A36. A combinação de simulações explícitas (*Abaqus*) para geração do núcleo físico com MLPs atuando como modelos substitutos viabilizou a predição da integridade das chapas ao sopro de cargas esféricas sem invólucro, detonadas ao ar livre. A validação via *K-Fold* ($K = 10$) atestou um erro de 1,60 mm na deflexão residual e um *F1-Score* de 92,36% na predição de rupturas, entregando uma ferramenta com resposta praticamente imediata (frações de milissegundos).

Adicionalmente, a pesquisa demonstrou que o desbalanceamento inicial das classes estruturais, obstáculo em cenários no limiar da falha iminente, foi mitigado com sucesso pelo arcabouço de *Active Learning*. O desdobramento da amostragem adaptativa em fases consecutivas e direcionadas permitiu enriquecer metodologicamente a minoria estatística na zona de incerteza plástica, expandindo a densidade local de dados na fronteira da ruptura sem incorrer no desperdício de recursos computacionais associado a simples varredura aleatória.

Sob a perspectiva de arquitetura para os modelos, a proposta de uma topologia bifurcada apresentou resultados estáveis para as predições. Ao segmentar os dados de treinamento para um classificador probabilístico e um regressor contínuo, os algoritmos isolam as descontinuidades provocadas pela exclusão de elementos finitos feitas no *solver Abaqus*. Esse isolamento previne que a predição da flecha residual tenha as singularidades numéricas da ruptura do material, garantindo superfícies de resposta topologicamente suaves (coerentes com as leis da mecânica dos sólidos).

Outra vantagem relevante dos modelos treinados é a possibilidade de exploração inversa do espaço paramétrico. Uma vez aprendida a fronteira de ruptura, a rede pode ser consultada iterativamente para estimar, por exemplo, quais distâncias de afastamento são esperadas para provocar rompimento dada uma carga explosiva e uma espessura de chapa, enquanto em simulações clássicas por elementos finitos cada nova combinação exigiria a execução de uma nova análise explícita.

Por fim, a consolidação destas redes neurais em arquivos de inferência instantânea (.pkl) viabilizou a transição de um regime de integração numérica de equações diferenciais altamente dispendioso para uma fase de predição em tempo real na escala de 0,4 ms. Essa aceleração aponta para uma abordagem na engenharia de defesa onde o modelo substituto

é capaz de gerar diretrizes de projeto quase instantâneos e otimizar substancialmente o planejamento e os custos de campanhas experimentais, reduzindo drasticamente a necessidade empírica de detonações em arena. Como trabalhos futuros, destaca-se a expansão do espaço paramétrico para incluir ângulos de incidência oblíquos e diferentes geometrias, bem como a validação experimental em arena, utilizando os arranjos sugeridos pela fronteira de ruptura da MLP.

DISPONIBILIDADE DE CÓDIGO E DADOS

Todos os *scripts* de automação do *solver Abaqus*, os códigos de treinamento das Redes Neurais (Python/*Scikit-learn*), o arquivo de simulação (.cae), o *dataset* consolidado de 1500 simulações e os modelos preditivos serializados (*pickled models*) foram disponibilizados publicamente. O repositório também hospeda notas metodológicas estendidas sobre as limitações físicas e a parametrização da simulação: <https://github.com/VBettio/A36-Blast-MLP-Surrogate>.

REFERÊNCIAS

[1] H. Z. Xi, D. R. Kong, Y. Q. Peng, S. M. Zhang, Q. Shi, G. G. Le, "Prediction of spatial peak overpressure profile of air blast shocks using multiple linear regression and artificial neural network," *Journal of Physics: Conference Series*, vol. 2478, no. 7, p. 072036, 2023, doi: 10.1088/1742-6596/2478/7/072036.

[2] I. Goodfellow, Y. Bengio, A. Courville, *Deep Learning*. MIT Press, 2016.

[3] B. Settles, "Active learning literature survey," University of Wisconsin-Madison Department of Computer Sciences, Tech. Rep. 1648, 2009.

[4] Dassault Systèmes, *Abaqus Analysis User's Guide*, Dassault Systèmes Simulia Corp., Providence, RI, 2014.

[5] A. S. Augusto, G. Urgessa, J. A. F. F. Rocco, F. B. Mendonça, K. Iha, "Field blast tests and finite element analysis of a36 steel sheets subjected to high explosives," *Eng*, vol. 6, no. 8, p. 187, 2025, doi: 10.3390/eng6080187.

[6] C. N. Kingery G. Bulmash, "Airblast parameters from tnt spherical air burst and hemispherical surface burst," U.S. Army Ballistic Research Laboratory, Aberdeen Proving Ground, MD, Tech. Rep. ARBRL-TR-02555, 1984.

[7] G. R. Johnson W. H. Cook, "A constitutive model and data for metals subjected to large strains, high strain rates and high temperatures," in *Proceedings of the 7th International Symposium on Ballistics*, The Hague, Netherlands, 1983, pp. 541–547.

[8] T. Børvik, O. S. Hopperstad, T. Berstad, M. Langseth, "A computational model of viscoplasticity and ductile damage for impact and penetration," *European Journal of Mechanics-A/Solids*, vol. 23, no. 4, pp. 565–582, 2004.

[9] X. Teng T. Wierzbicki, "Evaluation of six fracture models in high velocity perforation," *Engineering Fracture Mechanics*, vol. 75, no. 1, pp. 111–139, 2008.

[10] A. Hillerborg, M. Modéer, P.-E. Petersson, "Analysis of crack formation and crack growth in concrete by means of fracture mechanics and finite elements," *Cement and Concrete Research*, vol. 6, no. 6, pp. 773–781, 1976.

[11] M. D. McKay, R. J. Beckman, W. J. Conover, "A comparison of three methods for selecting values of input variables in the analysis of output from a computer code," *Technometrics*, vol. 21, no. 2, pp. 239–245, 1979.

[12] A. Forrester, A. Söbester, A. Keane, *Engineering design via surrogate modelling: a practical guide*. John Wiley & Sons, 2008.

[13] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, É. Duchesnay, "Scikit-learn: Machine learning in python," *Journal of Machine Learning Research*, vol. 12, pp. 2825–2830, 2011.

[14] D. P. Kingma J. Ba, "Adam: A method for stochastic optimization," in *International Conference on Learning Representations (ICLR)*, 2015.

[15] L. Breiman, "Random forests," *Machine learning*, vol. 45, no. 1, pp. 5–32, 2001.

[16] V. Vapnik, *Statistical learning theory*. Wiley, 1998.