

Classificação de Imagens de Relatórios de Monitoramento de Estacas Hélice Contínua Através de Redes Neurais Convolucionais

Leonardo Alves da Silva

Engenheiro Civil, Consultor, Macaé, Brasil, leonardoas@poli.ufrj.br

Gustavo Vaz de Mello Guimaraães

Professor, Instituto Politécnico/UFRJ, Macaé, Brasil, guimaraes@macae.ufrj.br

Janaina SantAnna Gomide Gomes

Professora, Instituto Politécnico/UFRJ, Macaé, Brasil, janainagomide@gmail.com

Lucas Marques Pires da Silva

Engenheiro Civil, Benthic, Rio de Janeiro, Brasil, lucas.silva@coc.ufrj.br

RESUMO: As estacas tipo hélice contínua monitoradas vem ocupando um espaço cada vez maior no mercado brasileiro de fundações. Dentre seus benefícios inclui-se a capacidade de monitoramento através de sensores instalados na torre da perfuratriz (e.g.: pressão hidráulica, velocidade de avanço do trado, rotação do trado, pressão de concreto e velocidade de extração do trado). Esse sistema de monitoramento permite a tomada de decisão em tempo real, baseada em dados técnicos, para garantir que as estacas estejam em conformidade com os padrões de projeto. Utilizar a inteligência artificial para auxiliar na tomada de decisões na engenharia vem se destacando atualmente. Conciliar a aplicação de estacas hélice contínua monitoradas com o aprendizado de máquina é o atual desafio por diversos profissionais da área geotécnica. Assim, a presente pesquisa utiliza redes neurais convolucionais para realizar uma classificação multirrotulo dos boletins de monitoramento de estacas hélice contínua. Esta classificação visa determinar se existe algum tipo de falha em um ou mais dos cinco parâmetros normalmente medidos durante a execução destas estacas. Os resultados preliminares, realizados em um banco de dados com 3690 boletins de monitoramento de estacas hélice contínuas executadas em diversos municípios do Estado do Rio de Janeiro, se mostraram satisfatórios.

PALAVRAS-CHAVE: Aprendizado de Máquina, Redes Neurais Convolucionais, Estaca tipo Hélice Contínua Monitorada, Classificação Multirrotulos das Falhas.

ABSTRACT: Monitored continuous flight auger are occupying an increasingly large space in the Brazilian foundation market. Their benefits include the ability to monitor through sensors installed in the drill tower (e.g. hydraulic pressure, auger advance speed, auger rotation, concrete pressure and auger extraction speed). This monitoring system enables real-time decision-making, based on technical data, to ensure that the piles comply with the design standards. The use of artificial intelligence to aid decision making in engineering is gaining prominence these days. Reconciling the application of monitored continuous flight auger with machine learning is the current challenge for many professionals in the geotechnical field. This research uses convolutional neural networks to perform a multi-label classification of continuous auger pile monitoring reports. This classification aims to determine whether there is any type of failure in one or more of the five parameters normally measured during the execution of these piles. The preliminary results, carried out on a database of 3690 monitoring reports for continuous flight auger in various municipalities in the state of Rio de Janeiro, proved satisfactory.

KEYWORDS: Machine Learning, Convolutional Neural Networks, Monitored Continuous Flight Auger, Multi-label Fault Classification.

1 INTRODUÇÃO

No contexto da estabilidade e sustentação de construções civis, a engenharia de fundações é determinante para garantia da segurança frente à instabilidade do solo e à ocorrência de recalques, em conformidade com as exigências geotécnicas (NBR6122/2019). A crescente preferência pela adoção de estacas hélice contínua na engenharia civil se dá em função de uma série de vantagens técnicas que visam otimizar a eficiência e o desempenho das fundações. Além da eficiência durante a execução, caracterizada pelo processo contínuo de perfuração e concretagem, as estacas hélice contínua sobressaem-se pela redução do impacto ambiental. Isso é atribuído à minimização das emissões de ruídos e vibrações durante o processo de assentamento (Neto; Kochen, 2003). Essas estacas destacam-se, ainda, pela sua adaptabilidade a diversos tipos de solo e pela elevada capacidade de carga, possibilitando o monitoramento eficaz durante a execução.

Os relatórios de monitoramento de estaca hélice permitem o controle de qualidade da fundação devido aos parâmetros obtidos durante o monitoramento em sua execução, desde a entrada do trado no solo até a saída que ocorre concomitantemente com a concretagem, além de informações como a data, hora e especificações técnicas (Albuquerque, 2001). Essa abordagem fornece uma visão do desempenho da estaca hélice e permite uma avaliação para a tomada de decisões embasadas na otimização dos processos construtivos, tais como: realização de ensaios complementares para verificar a qualidade (integridade) do concreto da estaca e/ou ensaio para verificar sua capacidade de carga geotécnica. Em último caso, podendo até condenar a utilização daquela estaca em um projeto.

Por outro lado, a obtenção de informações por meio do monitoramento da estaca pode introduzir incertezas, sendo a confiabilidade desses dados diretamente vinculada à calibração do equipamento. A ausência desse processo pode comprometer significativamente a integridade e a confiabilidade das informações recebidas pelo sistema (Albuquerque, 2001). Nesse cenário, a implementação de técnicas avançadas de aprendizado de máquina se apresenta como uma abordagem estratégica para otimizar o tempo de interpretação desses dados, visando fornecer ao engenheiro ferramentas mais robustas para o auxílio da tomada de decisões, seja para condenar ou aprovar as estacas assentadas ao longo das obras de fundações.

As Redes Neurais Convolucionais (CNNs) são especialmente eficazes em tarefas de visão computacional (Murphy, 2012). Este modelo de aprendizado de máquina tem sido amplamente empregado no reconhecimento de padrões em imagens. O aumento do poder computacional, aliado à disponibilidade crescente de conjuntos de dados de treinamento, permitiu que CNNs atingissem desempenhos satisfatórios em tarefas visuais complexas, superando inclusive a capacidade humana (Géron, 2022). O foco desse trabalho é avaliar o uso da técnica de aprendizado de máquina para a análise automática dos relatórios de monitoramento de estaca hélice contínua. Busca-se encontrar soluções mais robustas na gestão de informações técnicas para promover uma interpretação mais precisa e detalhada dos dados coletados durante a execução da estaca, contribuindo para otimizar a eficiência e a segurança na realização de fundações em diversos contextos construtivos.

2 METODOLOGIA

2.1 Banco de Dados

O conjunto de dados analisado no estudo consistiu em 3690 relatórios de monitoramento de estaca hélice contínua, os quais foram gerados por meio do software "SaCi3" pela Geodigitus mediante licença. Esses relatórios foram de obras de estaca hélice contínua realizadas nos municípios do Estado do Rio de Janeiro, cujos diâmetros variaram de 30 a 50 centímetros e comprimentos de 5 a 28 metros. Em cada relatório, são destacados cinco parâmetros monitorados: pressão hidráulica (Hid), rotação (Rot), velocidade (Vel), pressão do concreto (Conc), e velocidade de extração (Ext). Os três parâmetros iniciais estão relacionados à perfuração do solo e os dois últimos à saída do trado. Além disso, é gerado um perfil estimado (Perf) com base no volume teórico e volume real gasto para a execução da estaca.

Inicialmente os relatórios foram classificados com 6 rótulos dependendo da sua falha e 1 rótulo associado ao relatório perfeito, ou seja sem falha. Os rótulos de falha podem acontecer ao mesmo tempo, o que é denominado como classificação multirrótulos. Nesse contexto, as falhas gráficas foram definidas quando qualquer segmento nos gráficos do relatório estivessem sem informações nos parâmetros de pressão hidráulica,

rotação, velocidade, e velocidade de extração. Adicionalmente, no parâmetro pressão do concreto foi considerado falha uma mudança abrupta de pressão ou ausência de informações gráficas no relatório. Por fim, a falha no perfil estimado foi determinada pelo preenchimento parcial do concreto na seção transversal ou pela ausência de informações gráficas também no segmento. Exemplos dessas falhas são ilustradas na Figura 1, assim como um relatório sem falha também é apresentado.

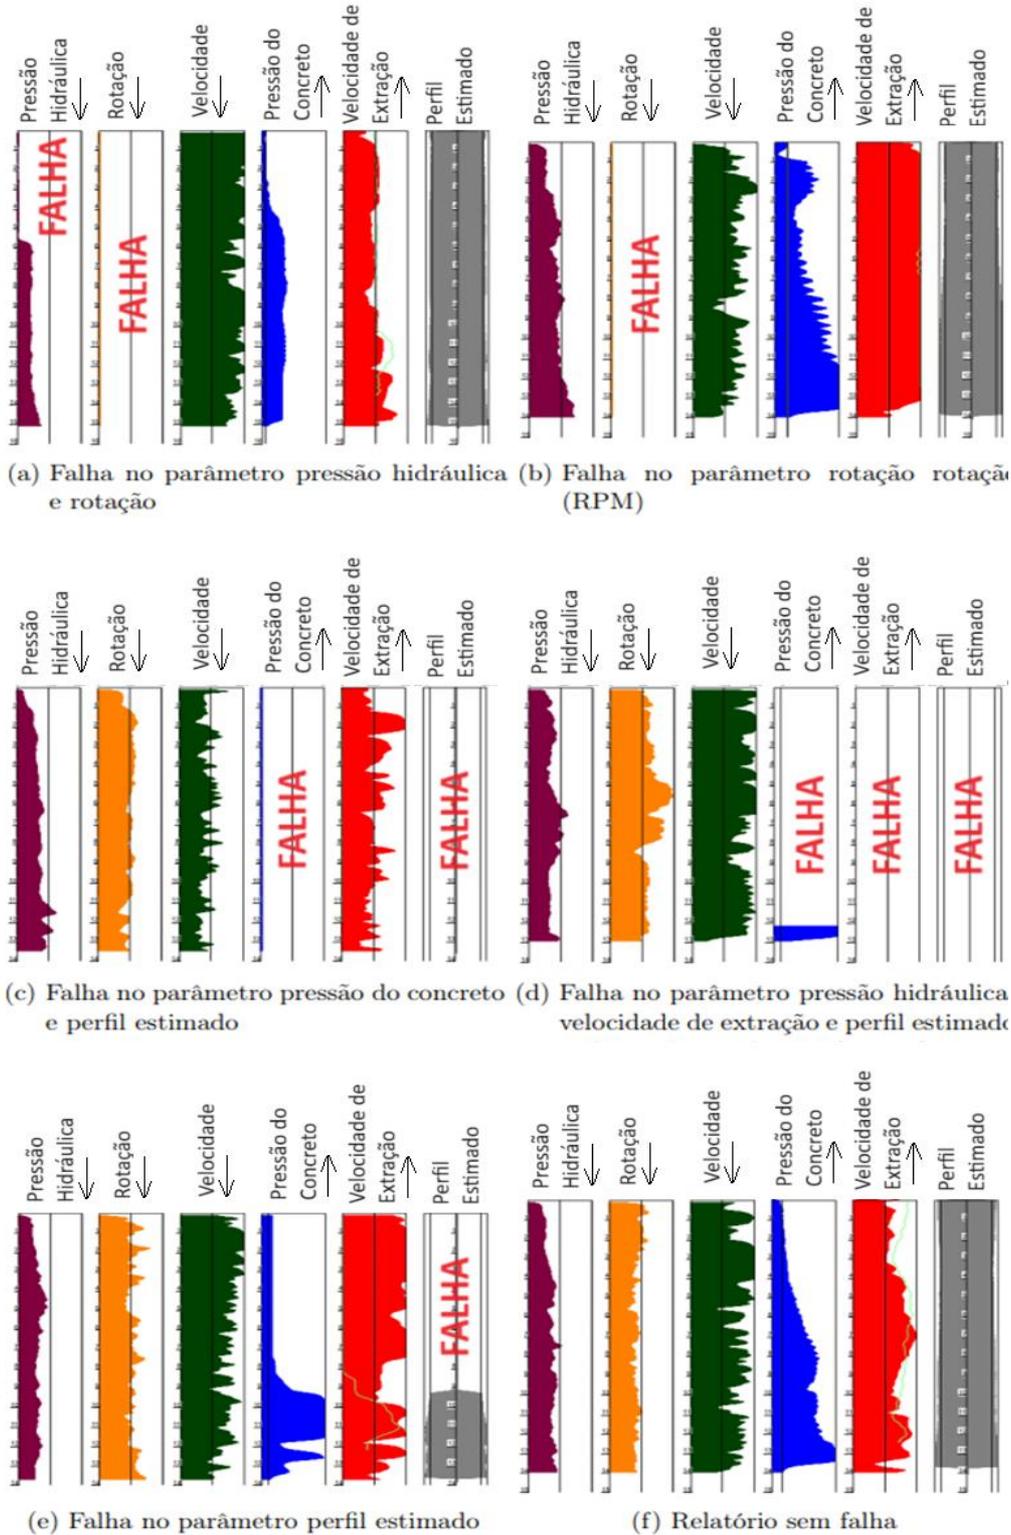


Figura 1. Rótulos dos relatórios: tipos de falhas ou sem falha.

Após a rotulação dos dados, foi gerado um gráfico mostrando o número de relatórios por tipo de falha gráfica, conforme ilustrado na Figura 2.

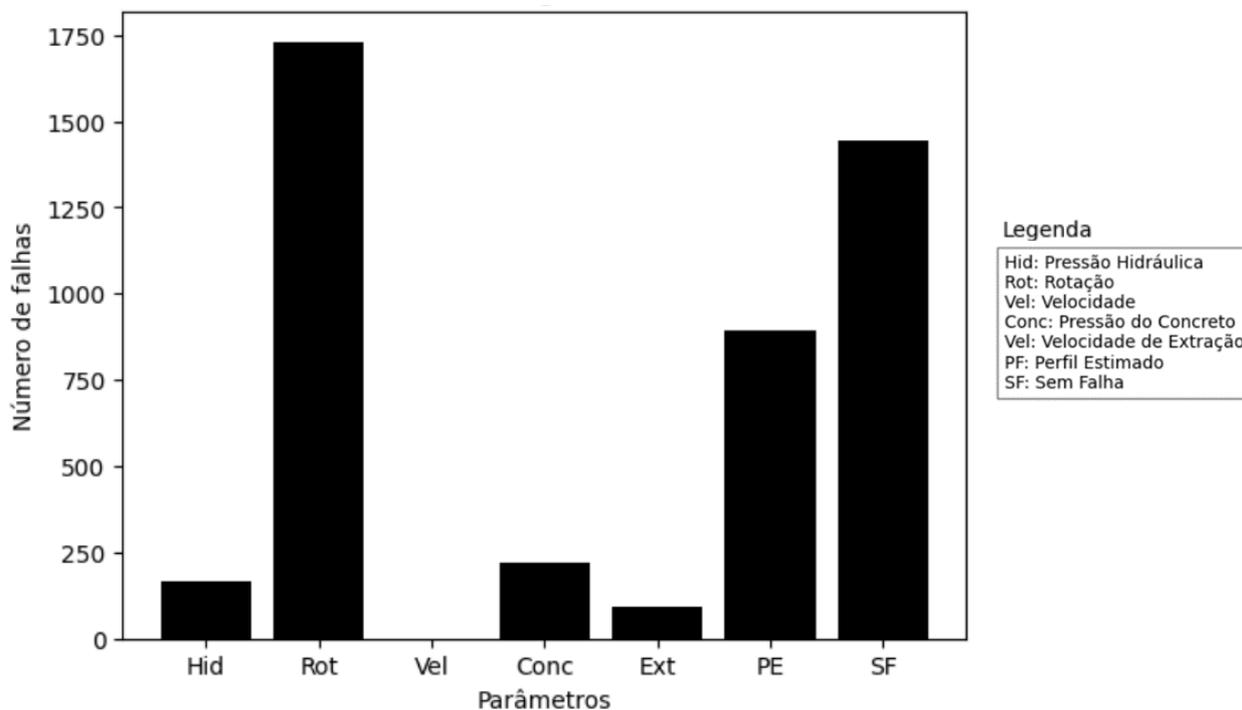


Figura 2. Falhas gráficas por rótulo.

Percebeu-se que o parâmetro da velocidade não possuía falha. Assim, naturalmente esse rótulo de falha atribuído anteriormente não foi considerado na pesquisa. Assim, o número de rótulos passou a ser 5 rótulos dependendo da sua falha e 1 rótulo associado ao relatório sem falha.

É importante destacar ainda, que a Figura 2 não apresenta a quantidade total de relatórios do banco de dados, uma vez que um relatório pode registrar mais de uma falha gráfica, resultando em contagens múltiplas para um mesmo dado.

2.2 Seleção do Algoritmo de Aprendizado de Máquina

As Redes Neurais Convolucionais são apropriadas para trabalhar com dados complexos, como imagens, vídeos e áudios (Géron, 2022). As CNNs são constituídas de camadas de convolução, responsáveis pela extração de características das imagens; camadas de *pooling*, cuja a finalidade é reduzir gradualmente a dimensionalidade da imagem, conseqüentemente a complexidade computacional do modelo; camadas de agrupamento, a qual tem por função utilizar as características extraídas para realizar a classificação das imagens; por fim, as funções de ativação permitem que o modelo de aprendizado de máquina representem relações mais complexas entre os dados, além de permitir a resolução de problemas de diversos domínios.

Nesse contexto, para realizar a classificação das imagens dos relatórios, foi desenvolvido um algoritmo de CNNs, através da linguagem de programa *Python*, com quatro camadas convolucionais seguidas de uma camada de *pooling* com função de ativação "*Tanh*". Em seguida, há três camadas totalmente conectadas, sendo que as duas primeiras também possuem função de ativação "*tahn*" e a última camada tem função de ativação sigmoide (Digitalsreeni Multilabel Classification, 2023).

2.3 Treinamento do Modelo

O conjunto de dados analisado no estudo consiste em 3690 relatórios de monitoramento de estaca hélice contínua. Para a divisão desses dados, foi empregada a biblioteca *Scikit-learn* do *Python* e utilizado o método *train-test-split*, responsável por particionar os dados. Os dados foram divididos em dois conjuntos: um

composto por 80% dos dados e outro por 20%. Este último conjunto, o qual representa 20% dos dados totais, foi reservado para o teste do modelo. No conjunto que englobou os 80% dos dados, 80% do grupo foi destinado ao treinamento do modelo, enquanto os 20% restantes foram utilizados para a validação. O parâmetro *random-state* foi utilizado a fim de garantir a reprodutibilidade da divisão dos dados. Ao definir um valor específico para o *random-state*, torna-se possível reproduzir exatamente a mesma divisão de dados em treinamento e teste sempre que o código for executado. Isso garante a consistência dos resultados e facilita a validação do modelo.

Uma consideração relevante é o desbalanceamento de exemplos de rótulos de diferentes rótulos presente no conjunto de dados, onde um grupo de rótulos possui um número significativamente maior de exemplos (indicando falhas nos mesmos parâmetros) em comparação com outro grupo de rótulos, que contém poucos exemplos. Para abordar esse desequilíbrio, o parâmetro *stratify* foi empregado na divisão dos dados. Essa abordagem assegura que os diferentes grupos de rótulos sejam representados de forma proporcional nos conjuntos de treinamento, validação e teste, evitando assim que o modelo adquira viés, ou seja, que aprenda de forma desigual, privilegiando o grupo de rótulos com mais exemplos em detrimento do grupo com menos exemplos. A Tabela 1 mostra a divisão do conjunto de dados após a utilização do *stratify*.

Tabela 1. Divisão dos Dados.

Rótulos	Treino	Validação	Teste
Sem Falha	933	225	290
Rotação	787	199	246
Perfil Estimado	238	55	74
Rotação, Perfil Estimado	159	50	52
Pressão Hidráulica, Rotação	74	24	25
Pressão do Concreto, Perfil Estimado	66	14	20
Pressão de Concreto, Velocidade de Extração, Perfil Estimado	30	6	9
Rotação, Pressão de Concreto, Velocidade de Extração, Perfil Estimado	26	6	7
Pressão Hidráulica, Rotação, Perfil Estimado	22	2	7
Rotação, Pressão de Concreto, Perfil Estimado	21	5	6
Pressão Hidráulica, Rotação, Pressão de Concreto, Velocidade de Extração, Perfil Estimado	3	0	1
Velocidade de Extração, Perfil Estimado	3	0	1
Pressão Hidráulica, Rotação, Pressão de Concreto, Perfil Estimado	2	1	1

2.3 Análise de Desempenho

Para representar os resultados obtidos pelas CNNs, a Matriz Confusão, conforme ilustrada na Figura 3, é uma ferramenta útil de avaliação de classificadores. Ela é uma matriz quadrada na qual as linhas correspondem às classes reais, e as colunas às classes previstas. As entradas localizadas na diagonal principal da matriz de confusão representam as classificações corretas, enquanto as demais entradas indicam o número de amostras de uma classe que foram erroneamente classificadas como pertencentes a outra classe. Consequentemente, é possível relacionar as entradas da matriz de confusão aos conceitos de falso positivo (FP) e falso negativo (FN), associados aos erros de classificação. Para uma visão mais abrangente, as amostras corretamente classificadas pertencentes à classe positiva são denominadas verdadeiros positivos (TP), enquanto as amostras corretamente classificadas pertencentes à classe negativa são denominadas verdadeiros negativos (TN) (Cerri, 2010).

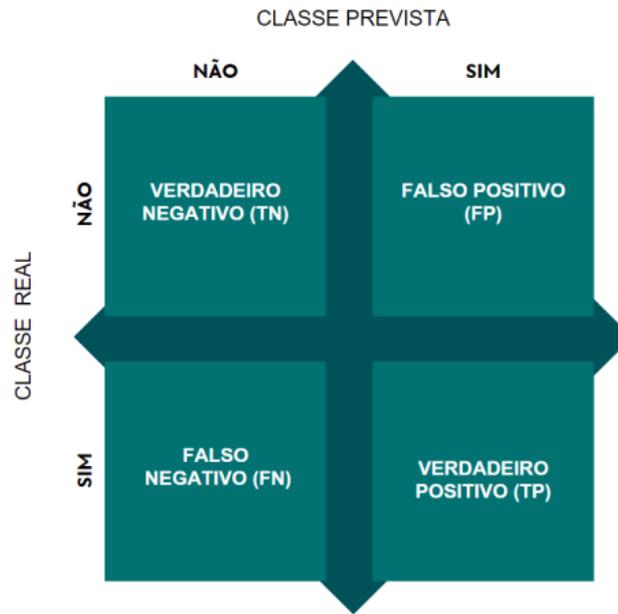


Figura 3. Matriz confusão.

Nesse sentido, é possível estabelecer relações entre os erros e acertos obtidos pelo modelo, identificando métricas de desempenho que orientem a avaliação de modelos de *Machine Learning* consoante o contexto de desenvolvimento. Para (Murphy, 2012), existem várias maneiras de resumir a matriz confusão, sendo mais comum a utilização de métricas como a acurácia, precisão, *recall* e *F1-Score*.

A acurácia empregada para mensurar a proporção de dados previstos corretamente pelo modelo em relação ao total dos dados. Essa métrica revela-se particularmente valiosa em cenários nos quais há dados cujo rótulos são equilibrados, de modo assegurar uma ponderação equivalente na classificação entre as categorias, o que não é o caso deste trabalho. A acurácia é dada pela equação 1:

$$Acurácia = \frac{TN+TP}{TN+TP+FN+FP} \quad (1)$$

A precisão é uma métrica que mede a proporção de exemplos positivos corretamente identificados em relação a todos os exemplos que o modelo classificou como positivos. É utilizada como uma métrica de desempenho quando o objetivo é limitar o número de falsos positivos, dada pela equação 2:

$$Precisão = \frac{TP}{TP+FP} \quad (2)$$

O *recall* é uma métrica que mede a capacidade do modelo de prever classes positivas reais. Em outras palavras, é a proporção de exemplos positivos corretamente identificados em relação a todos os exemplos positivos existentes; isto é, quando é importante evitar falsos negativos, conforme equação 3:

$$Recall = \frac{TP}{TP+FN} \quad (3)$$

Por fim, o *f1score* é obtido por meio de uma média harmônica da precisão e do *recall*, onde uma pontuação F1 atinge seu melhor valor em 1 e pior em 0, conforme equação 4:

$$f1_{score} = 2 \times \frac{precisão \times recall}{precisão+recall} \quad (4)$$

3 APRESENTAÇÃO E ANÁLISE DOS RESULTADOS

A Figura 4 apresenta as matrizes confusão que determinam a quantidade de erros e acertos do modelo em relação aos dados de teste dos casos estudados. Vale lembrar que a diagonal principal representa os acertos do modelo.

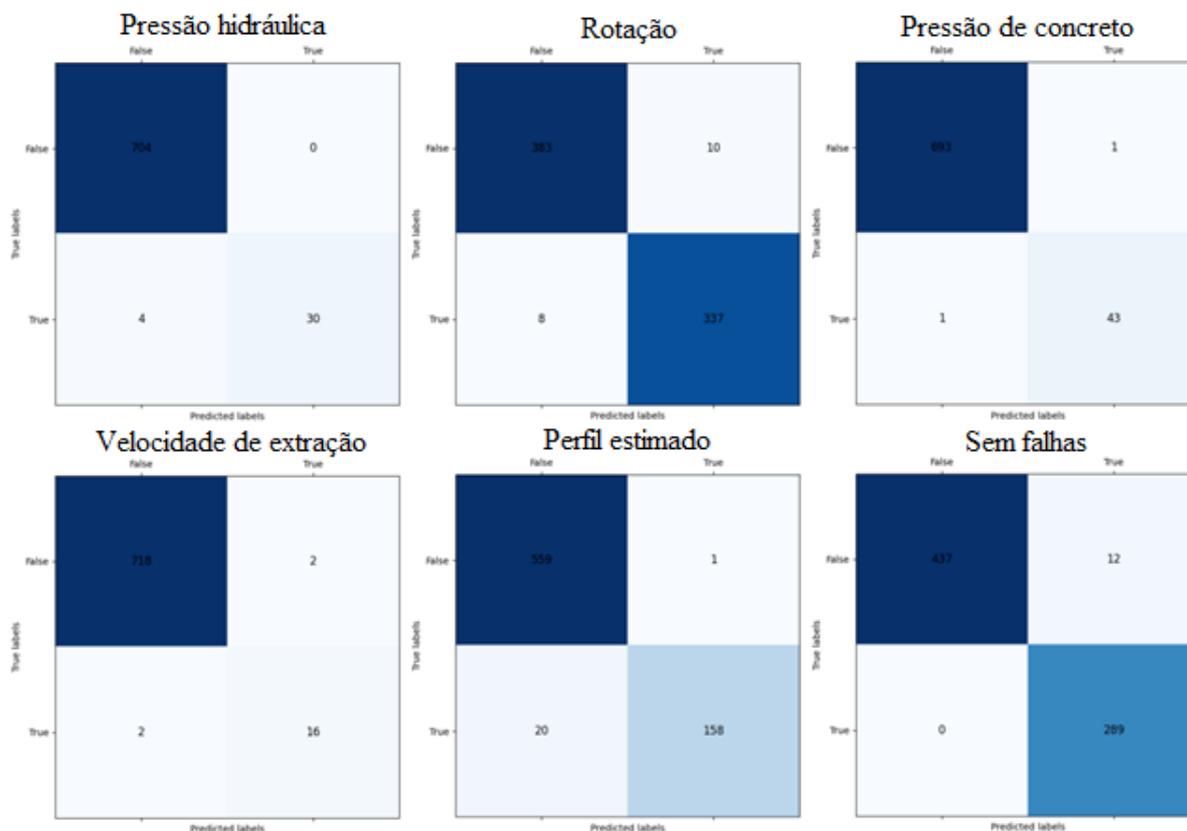


Figura 4. Matrizes confusão do modelo.

Nota-se que o menor erro previsto (quantidade de relatórios classificados de forma errada sobre número total de relatórios) pelo modelo foi em relação ao parâmetro “Pressão do Concreto”, correspondente a 0,27%. Por outro lado, o maior erro previsto foi sob exemplos que possuem falha no parâmetro “Perfil Estimado”, com 2,8%.

O relatório de desempenho, conforme apresentado na Tabela 2, exhibe as métricas (precisão, *recall* e *F1score*) resultantes da arquitetura de Redes Neurais Convolucionais, quando alimentadas pelos dados de teste, ou seja, 20% do banco de dados.

Tabela 2. Divisão dos dados de teste.

Métrica	Pressão Hidráulica	Rotação	Pressão Concreto	Velocidade de Extração	Perfil Estimado	Sem Falha
Precisão	1.00	0.97	0.98	0.89	0.99	0.96
Recall	0.88	0.98	0.98	0.89	0.89	1.00
$F1_{score}$	0.94	0.97	0.98	0.89	0.94	0.98

O modelo alcançou sua maior precisão ao identificar relatórios com falhas gráficas no rótulo "Pressão Hidráulica". Em contraste, a precisão foi menor ao identificar relatórios com falhas gráficas no parâmetro "Velocidade de Extração". No que diz respeito ao *recall*, os relatórios “Sem Falhas” gráficas alcançaram um *recall* de 100%, enquanto os relatórios com falhas no parâmetro "Velocidade de Extração" também apresentaram o menor *recall*. Em relação ao *F1-score*, os relatórios “Sem Falhas” e com falhas gráficas na “Pressão do Concreto” obtiveram a pontuação mais alta, ao passo que os relatórios com falhas no parâmetro "Velocidade de Extração", mais uma vez, tiveram a pontuação mais baixa.

Nesse sentido, como o *F1-score* é uma média harmônica entre *recall* e precisão, a classificação das falhas gráficas em relatórios de estaca hélice contínua monitorada alcançou resultados satisfatórios, indicando a viabilidade da utilização do modelo de Redes Neurais Convolucionais na classificação multirrótulos de boletins de monitoramento de estacas hélice contínuas, um dos campos da engenharia de fundações.

4 CONSIDERAÇÕES FINAIS E CONCLUSÕES

A pesquisa teve como objetivo avaliar o uso da técnica de aprendizado de máquina para a análise automática de 3690 relatórios de monitoramento de estaca hélice contínua, com o objetivo de otimizar o tempo de interpretação desses dados.

Esses relatórios foram de obras de estaca hélice contínua realizadas nos municípios do Estado do Rio de Janeiro, cujos diâmetros variaram de 30 a 50 centímetros e comprimentos de 5 a 28 metros. Os relatórios foram classificados com 5 rótulos dependendo da sua falha (pressão hidráulica, rotação, pressão do concreto, velocidade de extração e perfil estimado) e 1 rótulo associado ao relatório sem falhas. Destaca-se que os rótulos de falha podem acontecer ao mesmo tempo, o que é denominado como classificação multirrótulos.

Foi empregada uma arquitetura de Redes Neurais Convolucionais para avaliar sua capacidade de classificação dos relatórios de estacas hélice contínua, buscando fornecer resultados eficazes quando a quantidade de dados a ser analisada é muito grande.

A matriz confusão - associada as métricas de acurácia, precisão, *recall* e *f1score* - é uma ferramenta útil de avaliação de classificadores e foi utilizada para representar os resultados obtidos pelas CNNs.

No geral, a arquitetura alcançou um resultado satisfatório. Isso é corroborado pelo elevado valor de *F1-score* alcançado para cada um dos seis rótulos avaliados, ambos acima de 89%.

Com base nos resultados apresentados, conclui-se que as Redes Neurais Convolucionais representam uma alternativa viável para a classificação multirrótulos de falhas em relatórios de estaca hélice contínua monitorada, auxiliando os engenheiros de fundações nas corretas tomadas de decisões, como a execução de ensaios complementares para avaliar a integridade do concreto de uma estaca e/ou a realização de ensaios para determinar sua capacidade de carga geotécnica. Em situações extremas, essas avaliações podem até resultar na desqualificação de uma determinada estaca para uso em um projeto específico.

REFERÊNCIAS BIBLIOGRÁFICAS

- Associação Brasileira de Normas Técnicas (2019). NBR 6122. *Projeto e execução de fundações*. Rio de Janeiro.
- Albuquerque, P. J. R. (2001). *Estacas escavadas, hélice contínua e ômega: estudo do comportamento à compressão em solo residual de diabásio, através de provas de carga instrumentadas em profundidade*. São Paulo: Escola Politécnica da Universidade de São Paulo.
- Cerri, R. (2010). *Técnicas de classificação hierárquica multirrótulo*. Dissertação de Mestrado, Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos.
- DigitalSreeni Multilabel Classification (2023). https://github.com/bnsreenu/python_for_microscopists/blob/master/142-multi_label_classification.py. Acesso em 2023/05/18.
- Géron, A., (2022). *Mãos à obra: Aprendizado de máquinas com scikit-learn e tensorflow*. Alta Books.
- Neto, J.A.A. e Kochen, R. (2003). *Estacas hélice contínua e ômega: aspectos executivos*. Revista Engenharia.
- Massad, D. F., & de Carvalho, D. D. (2001). *Estacas escavadas, hélice contínua e ômega: estudo do comportamento à compressão em solo residual de diabásio, através de provas de carga instrumentadas em profundidade*.
- Multilabel classification using Keras*. (2020, July 16). [Video]. <https://www.youtube.com/watch?v=hraKTseOuJA&t=1001s>. Retrieved March 3, 2023, from https://github.com/bnsreenu/python_for_microscopists/blob/master/142-multi_label_classification.py.
- Murphy, K. P. (2012). *Machine learning: A probabilistic perspective*. MIT Press.