

Inteligência Artificial na Inspeção Ferroviária: Redes Neurais para Análise de Lastro via GPR

Felipe Augusto Tavares
*Pós-Graduação em Instrumentação, Controle e
Automação de Processos de Mineração.
Universidade Federal de Ouro Preto*
Ouro Preto, Brasil
felipe.tavares2@aluno.ufop.edu.br

Aginaldo José da Rocha Reis
*Departamento de Engenharia de
Controle e Automação.
Universidade Federal de Ouro Preto*
Ouro Preto, Brasil
reis@ufop.edu.br

Eleir Mundim Bortoleto
Instituto Tecnológico Vale.
Ouro Preto, Brasil
eleir.bortoleto@itv.org

Glauco Ferreira Gazel Yared
*Departamento de Engenharia Elétrica.
Universidade Federal de Ouro Preto*
João Monlevade, Brasil
glauco@ufop.edu.br

Ricardo Luiz da Silva Adriano
*Departamento de Engenharia Elétrica.
Universidade Federal de Minas Gerais*
Belo Horizonte, Brasil
rluiz@cpdee.ufmg.br

Resumo—Este trabalho investiga o uso de *Long Short-Term Memory (LSTM)* e *1D convolutional neural networks (CNN 1D)* na classificação automática de dados de *ground penetrating radar (GPR)* para avaliação de lastro ferroviário. A metodologia deste trabalho compreende três etapas: aquisição dos dados de GPR em um lastro montado em laboratório, classificação dos sinais de GPR em quatro classes: lastro bom, lastro colmatado, lastro com água e lastro com minério, e a utilização das redes LSTM e CNN 1D para classificar o conjunto dos dados. Os resultados obtidos demonstram que ambas as redes alcançaram acurácia média superior a 99%, com a CNN apresentando menor tempo de processamento em comparação à LSTM. Esses achados evidenciam o potencial das arquiteturas na tarefa de classificação dos sinais de GPR e na identificação automatizada das diferentes condições do lastro, contribuindo para estratégias de manutenção preditiva em ferrovias.

Palavras-chave—Radar de Penetração no Solo, Lastro ferroviário, Redes neurais recorrentes, Redes neurais convolucionais 1D, Classificação automática, manutenção preditiva.

I. INTRODUÇÃO

O desenvolvimento do sistema ferroviário tem se consolidado como uma das principais forças para o avanço tecnológico. A evolução das ferrovias não só revolucionou os meios de transporte e logística, como também impulsionou inovações tecnológicas nas mais diversas áreas [1]. As linhas ferroviárias são constituídas por componentes como trilhos, fixadores, placas de apoio, lastro e sublastro, entre outros elementos [2].

O lastro é um dos componentes mais importantes da via férrea. Sua manutenção e estabilidade estão diretamente ligadas à longevidade dos trilhos ferroviários. O lastro é composto de agregados em diversas granulometrias. A interação entre as partículas de lastro ajuda a ferrovia a transferir as cargas do trem para o solo [3].

Uma camada de lastro limpa e permeável, sustentada pelo sublastro, resulta em uma subestrutura estável e de alto desempenho [4]. A eficiência do lastro, por sua vez, é comprometida

por diversos fatores, tais como a contaminação por finos e materiais estranhos, drenagem inadequada, compactação em excesso e impactos das cargas dinâmicas dos trens [5]. As técnicas de monitoramento desse ativo incluem métodos de geofísica e de sensoriamento remoto, como reflexão e refração sísmica [6], investigações magnéticas e gravimétricas [7], pesquisas de resistividade [8], testes de ondas de superfície contínuas [9], LiDAR [10], radiometria infravermelha [11] e *Ground Penetrating Radar (GPR)* [12]. O GPR é considerado uma tecnologia rápida e eficaz para a avaliação da condição do lastro ferroviário [4]. Geralmente, a análise visual e a perfuração em campo são outros meios para a análise do lastro e são amplamente utilizados, a fim de obter o índice de incrustação, peneirando-se a amostra suja [13]. Entretanto, esse meio é caro e intrusivo.

O lastro necessita de uma condição geométrica e mecânica mínima para desempenhar adequadamente suas funções, como resistência, estabilidade, transferência de carga e drenagem da água, características que dependem muito do seu funcionamento. O lastro é considerado o principal componente da via férrea e a sua manutenção correta garante a segurança da via e reduz os custos de manutenção [14].

Embora existam muitas técnicas que vêm sendo empregadas na avaliação do lastro de uma ferrovia, neste trabalho dá-se o foco na técnica relacionada ao GPR, cujo princípio de funcionamento consiste em antenas transmissoras que emitem ondas eletromagnéticas para o interior da camada do lastro, de modo que quando estas ondas encontram uma camada limite ou areia com diferentes propriedades dielétricas, as ondas são refletidas e espalhadas, assim as antenas receptoras registram o tempo e a amplitude da onda de retorno [15]. Porém, a interpretação dos dados do GPR é uma tarefa desafiadora e demorada, que requer intervenção especializada [16].

Os dados de GPR são complexos, de alta dimensão e redundantes, além de apresentarem níveis significativos de

ruídos. Essas características dificultam a utilização de métodos tradicionais de aprendizado de máquina. Nesse contexto, técnicas de aprendizado profundo, tais como redes neurais recorrentes (LSTM) e redes neurais convolucionais unidimensionais (CNNs 1D), mostram-se mais adequadas para processar grandes quantidades de dados de treinamento e realizar uma interpretação adequada dos dados [17], [18].

A contribuição deste trabalho é apresentar uma metodologia para classificação automática de dados de GPR para avaliação do lastro ferroviário via redes LSTM e CNN 1d. Neste trabalho, a metodologia proposta consistiu em três etapas: a) a primeira etapa tratou de realizar a aquisição dos dados de GPR utilizando um lastro montado em um recipiente em laboratório; b) a segunda etapa consistiu em analisar os dados coletados e classificar os sinais de GPR em quatro classes, sendo elas: bom, colmatado (quando o lastro ferroviário perde sua capacidade de drenagem e estabilidade devido ao acúmulo de finos, como poeira e sedimentos), com minério e com água; c) na terceira etapa, as redes LSTM e CNN 1D foram utilizadas para classificar os conjuntos de dados do lastro ferroviário. Portanto, nesse sentido, busca-se aprimorar e automatizar a análise dos dados do GPR, sendo esta uma das principais contribuições deste artigo.

II. MATERIAIS E MÉTODOS

A. Equipamento Utilizado

O GPR utilizado nos experimentos é o GPR MALÅ ProEx [19], que consiste em um sistema de georadar, que utiliza a tecnologia de GPR para identificar variações nos materiais do subsolo, mapeando estruturas, camadas e objetos enterrados de forma não invasiva. O equipamento permite a conexão com diferentes antenas, o que possibilita ajustar a profundidade de penetração e a resolução do levantamento de acordo com os requisitos do estudo [20]. O GPR utilizado permite acoplar diversos módulos, módulos esses que permitem que sejam utilizados diferentes tipos de antenas. As antenas de alta frequência que podem ser acopladas no GPR são de 1,2 GHz, 1,6 GHz e 2,3 GHz, que são conectadas à unidade de controle por meio de um módulo coaxial. A Figura 1 exibe o dispositivo utilizado durante as aquisições dos dados.

B. Índice de Contaminação de lastro

Para classificar o lastro com minério e o lastro com água, de certo modo, é simples, pois os dois materiais foram depositados no lastro e mensurados previamente. Entretanto, para verificar se o lastro está bom ou colmatado, a análise não é simples. Dessa forma, para avaliar a condição do lastro e identificar qual sinal de GPR corresponde a ele, foi utilizado o índice de contaminação [21].

Um dos principais parâmetros que indicam a condição estrutural do lastro é o grau de incrustação, o qual reflete a condição estrutural do lastro em uma via férrea. O nível de contaminação e de compactação do lastro pode comprometer suas principais funções, tais como a estabilidade da via, a distribuição da carga e a drenagem eficiente [22].



Fig. 1. GPR MALÅ ProEx.

A intensidade dos sinais refletidos captados pelo GPR está diretamente relacionada ao contraste das propriedades dielétricas entre as camadas analisadas. Conforme ilustrado na Figura 2, as amplitudes das reflexões, identificadas como A_1 , A_2 e A_3 , são utilizadas para calcular as propriedades dielétricas dos materiais presentes nos meios investigados [23].




Fig. 2. Variação da tensão ao longo do tempo destacando os picos A_1 , A_2 e A_3 no sinal. Adaptado de [24]

O valor dielétrico pode ser calculado da seguinte maneira:

$$\varepsilon_1 = \left[\frac{1 + (A_1/A_m)}{1 - (A_1/A_m)} \right]^2, \quad (1)$$

Onde A_1 representa a amplitude do sinal refletido pela superfície, ε_1 corresponde à permissividade dielétrica da camada e A_m denota a amplitude do sinal refletido por uma placa metálica. O parâmetro A_m , que corresponde à amplitude do sinal GPR incidente, é determinado experimentalmente por meio da calibração com uma placa metálica plana durante a aquisição de dados. Devido à sua elevada condutividade elétrica, o metal se comporta como um refletor quase ideal para ondas eletromagnéticas, sendo perfeito para a calibração. Desse modo, para a realização dos testes, faz-se necessária a calibração em uma placa de metal e a sua amplitude é

utilizada para obter o parâmetro necessário para calcular o valor dielétrico do meio. Vale ressaltar que a amplitude do sinal está em unidades arbitrárias (u.a.), conforme a saída digital do sistema GPR, ou seja, os valores não representam medidas físicas absolutas, mas sim uma escala relativa.

A Tabela I apresenta a constante dielétrica e a velocidade de propagação de ondas eletromagnéticas para diferentes materiais, incluindo ar, água, lastro limpo (não degradado) e lastro deteriorado (usado). Realizando a coleta dos dados de GPR, e utilizando a equação 1 calcula-se o valor dielétrico do meio utilizando a tabela, faz-se possível determinar a condição do meio analisado.

TABLE I
LISTA DE PROPRIEDADES ELETROMAGNÉTICAS DE VÁRIOS MATERIAIS
CLARK2001ELECTROMAGNETIC

Material (* por volume)	ϵ_r	Velocidade (m/s)
Ar	1	3.00×10^8
Água	81	0.33×10^8
Lastro Limpo Seco	3.0	1.73×10^8
Lastro Limpo Úmido (5% água*)	3.5	1.60×10^8
Lastro Limpo Saturado	26.9	0.48×10^8
Lastro Usado Seco	4.3	1.45×10^8
Lastro Usado Úmido (5% água*)	7.8	1.07×10^8
Lastro Usado Saturado	38.5	0.58×10^8

C. Aquisição de Dados com Radar de Penetração no Solo

Os registros de GPR foram obtidos por meio de coletas de dados em lastro simulado em um recipiente cilíndrico de 2 m³. Foram obtidos 400 dados de GPR em um experimento em uma frequência de 2,3 GHz, essa frequência foi selecionada por ser recomendada para estudos de alta resolução em profundidades de até 40 cm. A altura do lastro varia entre 30 e 40 cm, garantindo assim sinais com melhor resolução. Os dados de GPR foram capturados e separados em quatro classes: lastro bom, lastro colmatado, lastro com minério e lastro com água.

Com o intuito de analisar o melhor recipiente para a montagem do lastro ferroviário, buscou-se na literatura recipientes utilizados por outros pesquisadores. Entre as principais opções encontradas, destacam-se os materiais utilizados, acrílico e plástico, com destaque para o uso de caixa d'água [25], [26].




Fig. 3. Capturas dos sinais de GPR no lastro montado.

O recipiente montado no campo de testes pode ser visto na Figura 3-A. Para a montagem do lastro, foi adquirida a brita

tipo 3, de gnaíse, brita esta composta por fragmentos de rocha com granulometria que varia entre 38 mm e 76 mm, utilizada especificamente para composição de lastro ferroviário. Para o preenchimento da caixa cilíndrica com esse material, estimou-se a necessidade de aproximadamente 2 toneladas de material.

A intensidade das reflexões exibidas pelo GPR estão diretamente ligadas à força de contraste e propriedade dielétricas entre as camadas analisadas. Conforme a Figura 2 a amplitude dessas reflexões identificadas como A_1 , A_2 e A_3 , são utilizadas para calcular a propriedade dielétrica dos meios [23]. A aferição da amplitude, utilizando uma placa de metal durante os testes, pode ser vista na Figura 3-B.

Para captar os dados do lastro com minério, foram utilizados aproximadamente 8 kg de minério de ferro para a contaminação do lastro. Já em relação ao lastro com água, foram utilizados aproximadamente 32 litros de água. Os valores para lastro bom e lastro colmatado foram obtidos conforme a Equação 1.

D. Long Short-Term Memory (LSTM)

As redes RNNs são especificamente projetadas para processar dados sequenciais, e a sua principal característica está na manutenção de um estado oculto, que armazena informações sobre as entradas anteriores. A estrutura é composta por três camadas principais, sendo elas: camada de entrada, camada oculta e camada de saída [27]. A cada passo de tempo, t , a RNN recebe um vetor de entrada, $\mathbf{x}_t$, e atualiza seu estado oculto, $\mathbf{h}_t$, usando a seguinte equação:

$$\mathbf{h}_t = \sigma_h(W_x \mathbf{x}_t + W_h \mathbf{h}_{t-1} + \mathbf{b}_h), \quad (2)$$

Em que W_x é a matriz de peso entre a camada de entrada e a camada oculta, W_h é a matriz de peso para a conexão recorrente, $\mathbf{b}_h$ é o vetor de polarização e σ_h é a função de ativação. A saída em cada passo de tempo, y_t é dada por:

$$y_t = \sigma_y(W_{hy} \mathbf{h}_t + \mathbf{b}_y), \quad (3)$$

Em que W_{hy} é a matriz de pesos entre as camadas oculta e de saída, $\mathbf{b}_y$ é o vetor de polarização, e σ_y é a função de ativação para a camada de saída. A Figura 4 exhibe a arquitetura padrão de uma rede RNN.




Fig. 4. Arquitetura básica de RNN. Adaptado de [27]

As redes RNN convencionais são eficazes para processar sequências, porém elas sofrem com problemas de longo prazo, como o desaparecimento ou explosão de gradientes. Para contornar esta limitação, as redes LSTM uma variante avançada das RNNs, usam um mecanismo de controle de fluxo de informações, que permite que o seu estado interno seja mantido e atualizado por longos períodos, tornando-se eficaz para tarefas que exigem dependência de longo prazo [27]. Cada célula LSTM contém três portas: a porta de entrada (i_t), a porta de esquecimento (f_t) e a porta de saída (o_t), que regulam o estado da célula c_t e o estado oculto h_t . A rede LSTM pode ser expressa da seguinte forma:

$$i_t = \sigma(W_x^i x_t + W_h^i h_{t-1} + b_i), \quad (4)$$

$$f_t = \sigma(W_x^f x_t + W_h^f h_{t-1} + b_f), \quad (5)$$

$$o_t = \sigma(W_x^o x_t + W_h^o h_{t-1} + b_o), \quad (6)$$

$$g_t = \tanh(W_x^g x_t + W_h^g h_{t-1} + b_g), \quad (7)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot g_t, \quad (8)$$

$$h_t = o_t \odot \tanh(c_t). \quad (9)$$

onde i_t é a porta de entrada, o_t é a porta de saída, f_t é o portão do esquecimento, h_t é o estado oculto, σ representa a função sigmoide, $\tanh$ é a função tangente hiperbólica, g_t é a entrada da célula, c_t é o estado da célula e $\odot$ representa a multiplicação elemento a elemento. A Figura 5 exibe a arquitetura interna de uma célula LSTM




Fig. 5. Arquitetura da rede LSTM. Adaptado de [27]

E. 1D convolutional neural networks

As redes CNNs 1D apresentam características propícias para processar dados sequenciais ou baseados em séries temporais. Elas operam aplicando filtros convolucionais ao longo de uma única dimensão, o que as torna ideais para analisar padrões em sinais [28]. A Figura 6 exibe a arquitetura padrão de uma rede CNN 1D.




Fig. 6. Arquitetura básica CNNs 1D. Adaptado de [29]

A arquitetura das CNNs 1D é composta por uma camada de entrada que recebe o sinal bruto, e sua camada de saída é uma rede *Multilayer Perceptron* (MLP) com a quantidade de neurônios correspondente ao número de classes. Entre a camada de entrada e a de saída, encontram-se as camadas convolucionais 1D que realizam operações de convolução ao longo da sequência, seguidas por funções de ativação e sub-amostragem para reduzir a dimensionalidade, caso necessário [30]. A convolução 1D entre um sinal de entrada $x[n]$ e um filtro $w[m]$ é definida como:

$$(y * w)[n] = \sum_{m=0}^{M-1} x[n-m] \cdot w[m] \quad (10)$$

onde $x[n]$ é o sinal de entrada, $w[m]$ é o filtro e $y[n]$ é o sinal de saída. Caso haja múltiplos canais de entrada, a convolução é dada por:

$$y_k[n] = \sum_{c=0}^{C-1} \sum_{m=0}^{M-1} x_c[n-m] \cdot w_{k,c}[m] + b_k \quad (11)$$

onde C é o número de canais e b_k é o termo de viés para o filtro k .

III. RESULTADOS

Com o intuito de realizar o treinamento das redes neurais, o primeiro passo realizado foi a classificação dos dados. Para realizar a classificação dos dados encontrados, primeiro foi necessário recriar certos cenários no lastro ferroviário. Cenários estes que são lastro colmatado (classe 1), lastro bom

(classe 2), lastro com minério (classe 3) e lastro com água (classe 4). Entretanto, para afirmar que o lastro está realmente neste cenário, é necessário utilizar uma técnica já validada que foi discutida na seção II-B. Os dados foram processados offline utilizando o software VS Code com a linguagem *Python* [31].

A Tabela II apresenta estatísticas descritivas referentes às quatro classes, incluindo a quantidade de amostras, a média geral e o desvio padrão dos sinais obtidos. A média geral dos sinais apresenta variações entre as classes, sugerindo uma diversidade entre elas. O mesmo acontece com o desvio padrão. Destaca-se a classe 2, que apresentou uma média global mais distinta em comparação às demais. A Figura 7 mostra a média dos 100 sinais de cada classe. Analisando-se visualmente, percebe-se distinções entre as classes. A classe 2 apresenta o comportamento mais distinto em relação às demais, o que corrobora com os dados da Tabela II. Vale ressaltar que a amplitude do sinal está em unidades arbitrárias, conforme a saída digital do sistema GPR. Dessa forma, tanto a amplitude do sinal quanto as médias e os desvios padrão, calculados a partir dos sinais de GPR, estão em unidades arbitrárias provenientes do sistema.

TABLE II
ESTATÍSTICAS DESCRITIVAS POR CLASSE: NÚMERO DE AMOSTRAS, MÉDIA GLOBAL E DESVIO PADRÃO DOS DADOS.

Classe	Nº de amostras	Média global	Desvio Padrão
Classe 1	100	2586,1155	2282,4335
Classe 2	100	306,7095	2708,3451
Classe 3	100	3333,1191	2132,7721
Classe 4	100	2234,9846	2301,8348




Fig. 7. Média dos sinais por classe.

A primeira arquitetura analisada foi a rede LSTM, que recebeu como entrada os sinais de GPR. Os sinais correspondem a 400 amostras de GPR, sendo 100 amostras para cada classe. Cada amostra consiste em uma sequência unidimensional com 296 pontos, representando as amplitudes do sinal. Por se tratar de um problema de classificação, cada uma das amostras recebeu um rótulo de 1 a 4 para a etapa de validação. A rede proposta foi constituída por duas camadas de *Long Short-Term Memory* (LSTM), arquitetura projetada para reter informações em sequências temporais, com 64 e 28 neurônios,

respectivamente. A primeira com 64 neurônios configurada com *return_sequences=True* e regularização L2 de $\lambda = 0.001$, seguida por uma camada de *Dropout* e *Batch Normalization*, e a segunda com 28 neurônios *return_sequences=False* com a mesma regularização, também acompanhada por *Dropout* e *Batch Normalization*. A camada final é uma Dense com 4 neurônios e ativação *softmax*. Dropout com taxa de 20% nas camadas convolucionais e 30% na camada densa. A quantidade de unidades LSTM e a quantidade de neurônios foi definida a partir de testes com o intuito de equilibrar a capacidade da rede de aprender e evitar o *overfitting*, o uso do *Dropout* foi empregado para evitar o sobreajuste. Nesta rede, dos 400 dados de GPR, 70% foram utilizados na etapa de treinamento e 30% na etapa de validação preservando o balanceamento entre as classes por meio de amostragem estratificada e aleatória. A Figura 8 apresenta a acurácia do modelo durante a etapa de treinamento e validação. A rede LSTM atingiu acurácia próxima de 100% a partir da época 10, tanto no treinamento quanto na validação, com a validação demorando mais épocas para atingir esta acurácia e apresentando algumas oscilações antes da época 30. Observa-se que o critério de parada foi ativado por volta da época 27. *EarlyStopping* foi o critério de parada utilizado, com paciência de 20 épocas, interrompendo automaticamente o treinamento, garantindo o modelo com os melhores pesos.




Fig. 8. Acurácia do modelo LSTM.

A Figura 9 mostra a função de perda durante a etapa de treinamento e validação da rede LSTM, ao longo das épocas. Nas primeiras épocas, há uma queda significativa da função de perda tanto para os dados de treinamento quanto para os dados de validação. Embora a função de perda de validação apresente algumas oscilações pontuais, ela converge para baixos valores, similares aos do treinamento, valores esses que indicam que houve um aprendizado efetivo do modelo, sugerindo uma boa capacidade de generalização.

A Figura 10 exibe a matriz da confusão que demonstra o desempenho da LSTM para a classificação das quatro classes propostas. Observa-se que todas as quatro amostras foram classificadas corretamente, com um total de 30 acertos para cada uma, resultando em uma acurácia de 100% verifica-se




Fig. 9. Função de perda do modelo LSTM.

que não há elementos fora da diagonal principal, indicando que o modelo não cometeu erros.




Fig. 10. Matriz de confusão correspondente à classificação das amostras pelas predições da rede LSTM.

A segunda rede analisada foi a rede CNN 1D, que recebeu como entrada os sinais de GPR. A rede proposta foi constituída por três camadas convolucionais 1D com 64, 128 e 256 filtros e *kernels* de tamanho 5 e 3, respectivamente, com ativação ReLU, seguidas por operações de *MaxPooling* (tamanho 2) e *Batch Normalization* em todas as camadas. A última camada é uma camada densa de 128 neurônios com função de ativação ReLU e *Dropout* de 30%. Para a escolha dos parâmetros da rede, foi feita experimentação empírica. Foram analisadas diferentes quantidades de filtros, tamanho de *Kernel* e configurações de *pooling*. As camadas de *Batch Normalization* e de *Dropout* inseridas entre os blocos tiveram como objetivo reduzir o *overfitting* e, consequentemente, mel-

horar a estabilidade do treinamento. Nesta rede, dos 400 dados de GPR, 70% foram utilizados na etapa de treinamento e 30% na etapa de validação. A Figura 11 exibe a acurácia do modelo durante a etapa de treinamento e validação. Observa-se que a acurácia nos dados de treinamento atingiu valores de 100%, a partir da época 30. Vale ressaltar que a acurácia da validação demonstrou oscilações consideráveis durante as primeiras 30 épocas. Para ambos modelos, empregou-se o mesmo critério de parada.




Fig. 11. Acurácia do modelo CNN

A Figura 12 exibe a função de perda durante a etapa de treinamento e validação da rede CNN, ao longo das épocas. Nota-se que a função de perda no conjunto de treinamento apresenta um decréscimo rápido, mantendo-se próxima de zero ao longo das épocas. Por outro lado, a função de perda no conjunto de validação apresenta um crescimento progressivo até a 15ª época. No entanto, após esse ponto, observa-se uma queda e estabilização da função de perda, convergindo para valores próximos a zero.




Fig. 12. Função de perda do modelo CNN

A Figura 13 exibe a matriz da confusão, que demonstra o desempenho da CNN, para a classificação das quatro classes propostas. Nota-se que as quatro amostras foram corretamente classificadas com 30 acertos de cada, atingindo uma acurácia de 100%. A ausência de elementos fora da diagonal principal sugere que o modelo não cometeu erros de classificação.




Fig. 13. Matriz de confusão correspondente à classificação das amostras pelas predições da rede CNN.

Para validar de forma mais robusta o desempenho dos modelos que foram propostos, nos dois modelos foram realizadas validações cruzadas com 5 *folds* com o intuito de verificar a capacidade de generalização dos modelos. A Figura 14 exibe a acurácia média e o desvio padrão da rede LSTM. A faixa sombreada em vermelho indica o desvio padrão da acurácia de validação entre os diferentes *folds*. Observa-se que o modelo apresenta variações significativas nos valores médios da acurácia nas primeiras épocas. O modelo apresenta desempenho estável, com pequena dispersão entre os *folds* após a 30ª época, evidenciando uma boa capacidade de generalização da rede LSTM.




Fig. 14. Acurácia média do modelo LSTM.

A Figura 15 exibe a acurácia média e o desvio padrão da rede CNN. Observa-se que, ao analisar o valor médio das acurácias, vemos que o modelo consegue atingir um valor de acurácia bastante satisfatório. Em vermelho, temos o valor

do desvio padrão da acurácia de validação entre os *folds*. Este valor demonstra que, mesmo em diferentes *folds*, a rede conseguiu atingir valores semelhantes de acurácia.




Fig. 15. Acurácia média do modelo CNN

Todos os experimentos foram realizados no cluster equipado com um processador Intel Xeon Gold 6354 de 3GHz e 256 GB de memória RAM. A rede CNN 1D apresentou um tempo de execução de 17,17 segundos, enquanto a rede LSTM demandou 64,27 segundos.

IV. CONCLUSÃO

Com base nos resultados preliminares deste estudo, as redes neurais dos tipos LSTM e CNN se mostraram efetivas na classificação automática de dados de GPR para avaliação do lastro ferroviário. Ao analisar os resultados obtidos, percebe-se que ambos os modelos tiveram 100% de acurácia na identificação das quatro condições do lastro (bom, colmatado, com minério e com água), evidenciando a habilidade deles de aprender e classificar os sinais de GPR. A rede LSTM mostrou uma convergência mais rápida durante a etapa de treinamento. A rede CNN apresentou um aumento crescente na função de perda para o conjunto de validação, seguido por uma redução gradual até atingir seu valor mínimo por volta da 30ª época. Ao utilizar a validação cruzada em 5 *folds* e verificar os seus resultados, reafirmou-se a robustez dos modelos, com seus desempenhos consistentes e com a baixa variabilidade entre os *folds*, obteve-se um bom nível de generalização do modelo. Apesar da existência de técnicas mais simples que as redes LSTM e CNN optou-se pelo uso de redes neurais profundas devido à natureza dos dados GPR. Em contrapartida, as redes neurais demonstraram grande capacidade de aprendizado, como demonstrado pelos resultados da validação cruzada.

Observou-se que o tempo de processamento demandado pela rede CNN foi menor se comparado com a rede LSTM, fato que pode estar ligado à sua natureza paralelizável das operações convolucionais. Em contrapartida, a rede LSTM demandou maior tempo computacional, porém com convergência mais rápida.

A metodologia proposta tem o potencial de reduzir os custos operacionais e auxiliar na detecção do lastro contaminado, uma vez que poderá substituir as inspeções manuais demoradas

por análises automatizadas. Outro ganho significativo é o fator segurança, já que a análise visual realizada diretamente na ferrovia, um ambiente extremamente perigoso, seria minimizada.

Portanto, os resultados preliminares sugerem que as redes neurais são uma alternativa para proporcionar um salto de qualidade em relação aos métodos tradicionais de inspeção, que são lentos, subjetivos e muitas das vezes invasivos. A automação do processo possibilita análises rápidas e precisas. Além do mais, a técnica proposta pode ser integrada a um sistema de monitoramento contínuo, permitindo manutenções preditivas, diminuindo possíveis custos, além de aumentar a segurança, que é o fator mais importante e a eficiência das ferrovias.

Vale ressaltar que foi utilizado um lastro simulado em ambiente controlado para a aquisição dos dados. Um lastro real pode ter ruídos não modelados, que podem dificultar o processo de classificação por parte das redes. Em ferrovias utilizadas diariamente, o lastro sofre compactação e rearrumação por conta da passagem constante das locomotivas, o que altera sua resposta dielétrica.

Como proposta para trabalhos futuros, recomenda-se a validação dos modelos em campo e a adição de mais dados variados, que serão de grande valia para avaliar-se melhor os achados deste trabalho. Vale destacar que esta pesquisa ainda está em andamento, com análises e experimentos adicionais previstos para etapas futuras.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), do Instituto Tecnológico Vale (ITV) e da Universidade Federal de Ouro Preto (UFOP).

REFERÊNCIAS

- [1] ZERBST, U.; MÄDLER, K.; HINTZE, H. Fracture mechanics in railway applications – an overview. *Engineering Fracture Mechanics*, v. 72, n. 2, p. 163–194, 2005.
- [2] WEI, D. et al. RTLSeg: A novel multi-component inspection network for railway track line based on instance segmentation. *Engineering Applications of Artificial Intelligence*, v. 119, p. 105822, 2023.
- [3] HUANG, S.; QIAN, Y. A prediction model for railroad ballast resilient modulus considering cyclic loading duration ratio. *Transportation Geotechnics*, v. 46, p. 101249, 2024.
- [4] ICHI, E.; DORAFSHAN, S. Spectral characterization of fouled railroad ballast using hyperspectral imaging. *Construction and Building Materials*, v. 394, p. 132076, 2023.
- [5] ZENG, K. et al. Investigation into the effect of railroad ballast fouling on the ballast movements and strain change using “SmartGrid”. *Transportation Geotechnics*, v. 48, p. 101307, 2024.
- [6] QUIROS, D. A.; BROWN, L. D.; KIM, D. Seismic interferometry of railroad induced ground motions: Body and surface wave imaging. *Geophysical Supplements to the Monthly Notices of the Royal Astronomical Society*, v. 205, n. 1, p. 301–313, 2016.
- [7] DING, X. et al. A reduction method for magnetic disturbance caused by DC railway system. *Earth, Planets and Space*, v. 73, p. 1–10, 2021.
- [8] RAHMAN, A. J. *Permeability, resistivity and strength of fouled railroad ballast*. 2013. Tese (Doutorado) – University of Kansas.
- [9] ZAGYAPAN, M.; FAIRFIELD, C. A. Continuous surface wave and impact methods of measuring the stiffness and density of railway ballast. *NDT & E International*, v. 35, n. 2, p. 75–81, 2002.
- [10] ALDAO, E. et al. Validation of solid-state lidar measurement system for ballast geometry monitoring in rail tracks. *Infrastructures*, v. 8, n. 4, p. 63, 2023.
- [11] CLARK, M.; McCANN, D. M.; FORDE, M. C. Infrared thermographic investigation of railway track ballast. *NDT & E International*, v. 35, n. 2, p. 83–94, 2002.
- [12] LIU, G. et al. Railway ballast layer inspection with different GPR antennas and frequencies. *Transportation Geotechnics*, v. 36, p. 100823, 2022.
- [13] KUO, C. Ground-penetrating radar to investigate mud pumping distribution along a railway line. *Construction and Building Materials*, v. 290, p. 123104, 2021.
- [14] SADEGHI, J. et al. Improvement of railway ballast maintenance approach, incorporating ballast geometry and fouling conditions. *Journal of Applied Geophysics*, v. 151, p. 263–273, 2018.
- [15] WANG, S. et al. State-of-the-art review of ground penetrating radar (GPR) applications for railway ballast inspection. *Sensors*, v. 22, n. 7, p. 2450, 2022.
- [16] KAHIL, N. S. et al. Automatic analysis of railway ground penetrating radar: Using signal processing and machine learning approaches to assess railroad track substructure. *Transportation Research Procedia*, v. 72, p. 3008–3015, 2023.
- [17] ÖZKAYA, Umut et al. Residual CNN+ Bi-LSTM model to analyze GPR B scan images. *Automation in Construction*, v. 123, p. 103525, 2021.
- [18] LIU, Huan et al. Combined CNN and RNN neural networks for GPR detection of railway subgrade diseases. *Sensors*, v. 23, n. 12, p. 5383, 2023.
- [19] GUIDELINE GEO. *MALA ProEx*. 2024. Disponível em: <https://www.guidelinegeo.com/product/mala-proex/>. Acesso em: 01 maio 2025.
- [20] AL-HEETY, A. J.; AL-KHALIDY, A. A.; AL-KHAFAJI, A. J. Ground penetrating radar in civil engineering application: Case study of multi-storey building foundation site to mapping subsurface features at the center of Karbala governorate, Iraq. *The Iraqi Geological Journal*, p. 49–66, 2016.
- [21] ARTAGAN, S.; BORECKY, V. Applicability of GPR on Turkish Railways. *Electronic Journal of Occupational Improvement and Research*, v. 1, p. 162–174, dez. 2015.
- [22] ANBAZHAGAN, P.; DIXIT, P. S. N.; BHARATHA, T. P. Identification of type and degree of railway ballast fouling using ground coupled GPR antennas. *Journal of Applied Geophysics*, v. 126, p. 183–190, 2016.
- [23] LOIZOS, A.; PLATI, C. Accuracy of pavement thicknesses estimation using different ground penetrating radar analysis approaches. *NDT & E International*, v. 40, n. 2, p. 147–157, 2007.
- [24] SAARENKETO, T.; SCULLION, T. Road evaluation with ground penetrating radar. *Journal of Applied Geophysics*, v. 43, n. 2–4, p. 119–138, 2000.
- [25] TOSTI, F. et al. An investigation into the railway ballast dielectric properties using different GPR antennas and frequency systems. *NDT & E International*, v. 93, p. 131–140, 2018.
- [26] ARTAGAN, S. S.; BORECKY, V. Advances in the nondestructive condition assessment of railway ballast: A focus on GPR. *NDT & E International*, v. 115, p. 102290, 2020.
- [27] MIENYE, I. D.; SWART, T. G.; OBAIDO, G. Recurrent neural networks: A comprehensive review of architectures, variants, and applications. *Information*, v. 15, n. 9, p. 517, 2024.
- [28] CACCIARI, Ilaria; RANFAGNI, Anedio. Hands-On Fundamentals of 1D Convolutional Neural Networks—A Tutorial for Beginner Users. *Applied Sciences* (2076-3417), v. 14, n. 18, 2024.
- [29] HOA, P. V. et al. One-dimensional deep learning driven geospatial analysis for flash flood susceptibility mapping: a case study in North Central Vietnam. *Earth Science Informatics*, v. 17, n. 5, p. 4419–4440, 2024.
- [30] KIRANYAZ, S. et al. 1D convolutional neural networks and applications: A survey. *Mechanical Systems and Signal Processing*, v. 151, p. 107398, 2021.
- [31] PYTHON SOFTWARE FOUNDATION. *The Python Tutorial*. 2023. Disponível em: <https://docs.python.org/3/tutorial/>. Acesso em: 01 maio 2025.