

Detecção de Hipóxia Fetal explorando Representações de Séries Temporais com Redes Neurais Convolucionais

André R. Coimbra^{1,2}, Maria Ribeiro^{1,3}, Ana Cristina Silva Rebelo⁴,
Antonio Oliveira-Jr^{1,5}

¹Instituto de Informática – Universidade Federal de Goiás (UFG)
Goiânia, Goiás – Brasil

²Instituto Federal de Educação, Ciência e Tecnologia de Goiás (IFG)
Goiânia, Goiás – Brasil

³Instituto de Eng. de Sistemas e Computadores, Tecnologia e Ciência (INESC TEC)
Porto – Portugal

⁴Instituto de Ciências Biológicas – Universidade Federal de Goiás (UFG)
Goiânia, Goiás – Brasil

⁵Fraunhofer Portugal AICOS
Porto – Portugal

andre.coimbra@ifg.edu.br, {rosarioribeiro, ana-rebelo, antoniojr}@ufg.br

Abstract. *This study explored the use of Recurrence Plot (RP) and Poincaré Plot (PC) as inputs for Convolutional Neural Networks (CNNs) in detecting fetal hypoxia from cardiotocography data. The experiments showed that RP achieved better overall performance (Sensitivity (Se) = $61.98\% \pm 10.9$; Specificity (Sp) = $63.58\% \pm 11.2$), being more effective in detecting critical patterns, especially in 15-minute segments. PC demonstrated greater stability in longer segments (Se = $65.62\% \pm 6.6$; Sp = $61.17\% \pm 12.3$), however was generally less effective in identifying hypoxia. The results suggest that RP is more suitable for capturing the nonlinear dynamics of fetal heart rate in automated monitoring systems.*

Resumo. *Este estudo explorou o uso do Gráfico de Recorrência (RP) e do Gráfico de Poincaré (PC) como entradas para Redes Neurais Convolucionais (CNNs) na detecção de hipóxia fetal a partir de dados de cardiotocografia. Os experimentos mostraram que o RP teve melhor desempenho geral (Sensibilidade (Se) = $61,98\% \pm 10,9$; Especificidade (Sp) = $63,58\% \pm 11,2$), sendo mais eficiente na detecção de padrões críticos, especialmente em segmentos de 15 minutos. O PC apresentou maior estabilidade em segmentos longos (Se = $65,62\% \pm 6,6$; Sp = $61,17\% \pm 12,3$), contudo, de maneira global, foi menos eficaz na identificação da hipóxia. Os resultados sugerem que o RP é mais adequado para capturar dinâmicas não lineares da frequência cardíaca fetal em sistemas automatizados de monitoramento.*

1. Introdução

A hipóxia fetal, caracterizada pela redução do oxigênio durante o desenvolvimento fetal, é uma condição grave que pode causar danos neurológicos permanentes ou até óbito neonatal [Kanagal and Praveen 2022]. A detecção precoce e precisa assegura intervenções

clínicas adequadas, minimiza impactos adversos no desenvolvimento fetal e evita cesáreas de urgência desnecessárias.

O cardiotocógrafo (CTG) é um aparelho regularmente utilizado na obstetrícia para monitorar simultaneamente a frequência cardíaca fetal (*fetal heart rate* – FHR) e as contrações uterinas (*uterine contractions* – UCs). O traçado gerado pelo CTG permite avaliar a frequência basal, as acelerações e as desacelerações da FHR em relação às UCs. Essas informações são cruciais para acompanhar a saúde fetal durante a gestação e no intraparto. Além disso, permitem diagnosticar condições de sofrimento fetal, como a hipóxia [Gunaratne et al. 2022].

Em [Silva et al. 2022] foi investigado o impacto de diferentes representações de séries temporais da FHR e algoritmos de compressão na detecção da hipóxia fetal. Os resultados apontaram que o Gráfico de Recorrência (*Recurrence Plot* - RP) e o Gráfico de Poincaré (*Poincaré Plot* - PC), associados ao algoritmo de compressão DEFLATE e ao formato de imagem TIFF, teriam um melhor desempenho nesse diagnóstico.

Em [Zhao et al. 2019] foi proposto um sistema de detecção de hipóxia fetal utilizando RP da FHR e Redes Neurais Convolucionais (*Convolutional Neural Networks* - CNNs), aproveitando a capacidade dessas redes de aprender características hierárquicas e espaciais, o que as torna eficazes na análise de séries temporais complexas.

Assim, este trabalho investigou a utilização de CNNs para o diagnóstico de hipóxia fetal a partir do RP e do PC. A pesquisa destaca a importância da escolha adequada de representações de séries temporais da FHR para otimizar o desempenho das redes neurais em contextos clínicos, visando melhorar os cuidados obstétricos e os resultados perinatais. Os experimentos foram realizados com um conjunto de dados clínicos reais, validando a aplicabilidade prática da proposta.

O restante do artigo está organizado da seguinte forma: a seção “2. Metodologia” descreve os métodos utilizados, incluindo a base de dados e as métricas para a análise dos resultados; a seção “3. Resultados e Discussão” apresenta a configuração dos experimentos, os resultados obtidos e uma análise do desempenho de cada representação; por fim, a seção “4. Conclusão” expõe as conclusões do estudo e sugestões para trabalhos futuros.

2. Metodologia

Esta pesquisa baseou-se na abordagem descrita em [Zhao et al. 2019], que utilizou Gráficos de Recorrência (RPs) da FHR e CNNs para o diagnóstico da hipóxia fetal. Desta forma, além dos RPs, este trabalho explorou também os Gráficos de Poincaré (PCs), visando avaliar o impacto da escolha da representação gráfica nesse diagnóstico.

A Figura 1 apresenta um diagrama da estratégia proposta neste trabalho, que pode ser resumida em quatro etapas: I) O sinal de FHR, obtido sem transformações do CTG, passa por um pré-processamento conforme descrito na seção 2.2; II) O sinal resultante é utilizado para gerar os RPs e PCs, conforme descrito nas seções 2.3.1 e 2.3.2, respectivamente; III) A seguir, CNNs são usadas para extrair e aprender as características das imagens geradas, de acordo com a seção 2.4. Ressalta-se que cada representação (RP e PC) é utilizada isoladamente, e não de forma conjunta. IV) Por fim, avalia-se o desempenho das propostas, considerando o valor de pH do sangue arterial umbilical como indicador de hipóxia fetal.

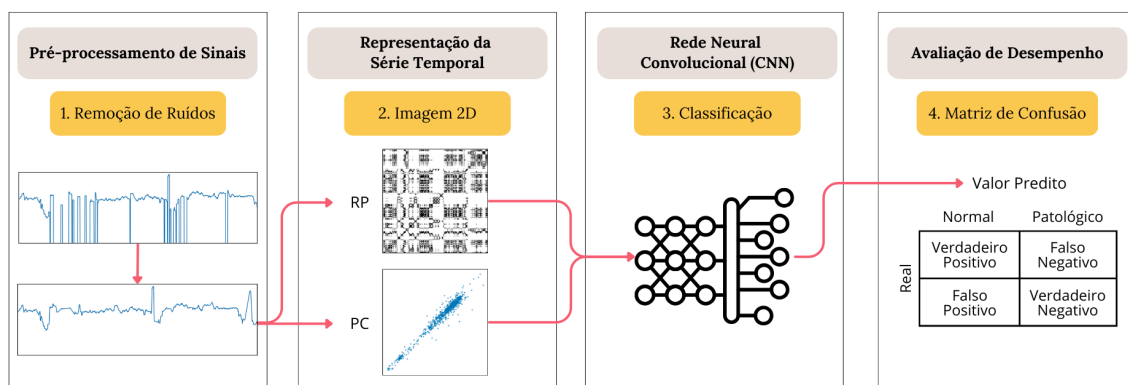


Figura 1. Diagrama da abordagem proposta utilizando duas representações de séries temporais – Gráfico de Recorrência (RP) e Poincaré (PC) – e CNN.

2.1. Base de Dados

Neste estudo, foi utilizada a base de dados de Cardiotocografia Intraparto da Universidade Técnica Tcheca (*Czech Technical University - CTU*) em Praga e do Hospital Universitário de Brno (*University Hospital in Brno - UHB*), conhecida como *CTU-CHB Intrapartum Cardiotocography Database* [Chudáček et al. 2014]. Trata-se de uma base de dados pública e de acesso livre, composta por uma coleção de 552 registros de CTG, cuidadosamente selecionados a partir de um total de 9164 registros. Cada registro possui até 90 minutos (min) de duração e contém a série temporal da FHR, o sinal de contração uterina (UC), além de informações clínicas sobre o feto, a mãe e o parto.

Desta maneira, além de fornecer a FHR e os sinais de UC, esta base de dados inclui informações relevantes, como a idade gestacional do feto em semanas, a idade materna, o tipo de parto, a duração do parto, o sexo do bebê, o peso ao nascer, o índice na Escala de Apgar e análises da amostra sanguínea da artéria umbilical, com parâmetros como o pH, que indica o grau de acidez do sangue. A Tabela 1 traz exemplos de parâmetros da base de dados e suas respectivas distribuições.

Tabela 1. Resumo de parte das informações disponíveis na base de dados de Cardiotocografia Intraparto CTU-CHB.

Parâmetro	Média	Mínimo	Máximo	Desvio Padrão
Idade gestacional (semanas)	39,99	37,0	43,0	1,13
Peso ao nascer (gramas)	3.400,43	1.970,0	4.750,0	454,78
Idade materna (anos)	29,67	18,0	46,0	4,54
pH	7,23	6,85	7,47	0,11

Seguindo estudos anteriores [Cömert et al. 2018, Zhao et al. 2019, Silva et al. 2022], os registros foram classificados como normais ou patológicos com base no valor de pH, adotando o limiar de 7,15. Ou seja, registros com valores de pH iguais ou superiores a esse limiar foram considerando normais. Assim, dos 552 registros, 447 foram classificados como normais e 105 patológicos. Para balancear as classes, 105 registros normais foram selecionados aleatoriamente, conforme a abordagem em [Zhao et al. 2019].

2.2. Pré-Processamento de Sinais

Os sinais de FHR da base de dados CTU-CHB são fornecidos sem processamento prévio, refletindo diretamente as leituras do CTG. A precisão dessas medições depende do posicionamento correto dos sensores e pode ser afetada por movimentos fetais e maternos, que são comuns devido ao desconforto e às dores causadas pelas UCs.

Logo, para tratar essas distorções, adotou-se uma abordagem que pode ser resumida em três etapas: detecção de lacunas, interpolação e identificação de valores discrepantes [Romano et al. 2014]. Segmentos zerados por mais de 15 segundos foram removidos, enquanto valores abaixo desse limiar foram corrigidos por interpolação linear. A interpolação também foi aplicada quando a variação entre valores adjacentes excedia 25 batimentos por minuto (bpm). Valores fora da faixa de 50 a 200 bpm foram removidos e preenchidos utilizando interpolação por spline de Hermite.

A Figura 2 mostra um segmento de 10 min do sinal original da FHR com distorções, comparado ao sinal após a aplicação das estratégias de pré-processamento.




Figura 2. Exemplo do resultado da etapa de pré-processamento.

Registra-se que os sinais de FHR inicialmente amostrados a 4 Hertz (Hz), foram filtrados com *antialiasing* (antisserrilhamento) e decimados (*downsampled*) por um fator de 4, gerando uma taxa final de 1 Hz, que preservava as características principais do sinal e permitia a geração de imagens de forma mais rápida e que demandavam menos memória.

2.3. Representações das Séries Temporais

RPs e PCs são representações gráficas de séries temporais que se apresentam como importantes métodos para a análise de padrões dinâmicos e não lineares. Com base em [Silva et al. 2022], propôs-se o uso desses gráficos para representar as séries temporais da FHR, utilizando imagens no formato TIFF e compressão DEFLATE, conforme os resultados do estudo.

2.3.1. Gráfico de Recorrência

O Gráfico de Recorrência, introduzido em [Eckmann et al. 1987], é um método gráfico usado para analisar sistemas dinâmicos complexos, permitindo visualizar padrões de recorrência em séries temporais e identificar periodicidade, caos e transições abruptas em dados não lineares.

A construção do RP é baseada na métrica de recorrência, utilizando um limiar de distância (ε) entre os estados, onde regiões escuras indicam recorrências e regiões claras, transições. A análise par a par dos pontos na série temporal conecta pontos próximos por uma linha, formando as regiões de recorrência. Para gerar um RP a partir de uma série temporal (x_1, \dots, x_n) , é necessário reconstruir o espaço de fases usando o método de atrasos de Takens [Faouzi 2021]:

$$\vec{x}_i = (x_i, x_{i+\tau}, \dots, x_{i+(m-1)\tau}), \quad \forall i \in \{1, \dots, n - (m-1)\tau\} \quad (1)$$

sendo m a dimensão de imersão e τ o atraso temporal. Assim, a matriz de recorrência \mathbf{R} é então definida como:

$$R_{i,j} = \Theta(\varepsilon - \|\vec{x}_i - \vec{x}_j\|), \quad \forall i, j \in \{1, \dots, n - (m-1)\tau\} \quad (2)$$

sendo Θ a função degrau de Heaviside, ε um limiar de proximidade e $\|\mathbf{X}_i - \mathbf{X}_j\|$ a distância entre os vetores no espaço de fases.

Resumidamente, ao construir o RP, três parâmetros podem ser ajustados: dimensão de imersão (m), atraso temporal (τ) e tolerância de distância (ε) [Zhao et al. 2019]. Assim, a Figura 3 apresenta os RPs de um registro normal e outro patológico, considerando segmentos de 10 min da FHR.

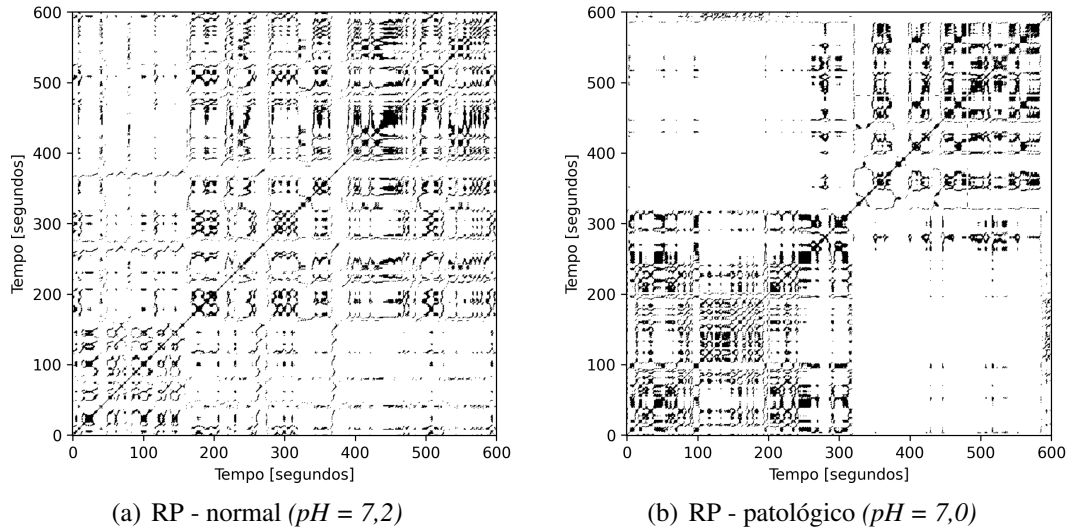


Figura 3. Gráfico de Recorrência (RP) de um registro normal e outro com hipóxia. Os parâmetros utilizados para gerar os RPs foram $m = 2$, $\tau = 1$ e $\varepsilon = 10$.

2.3.2. Gráfico de Poincaré

No contexto de avaliação da frequência cardíaca, o intervalo RR é o tempo entre dois batimentos cardíacos consecutivos. O Gráfico de Poincaré é uma representação bidimensional que correlaciona intervalos RR consecutivos, facilitando a visualização de padrões e irregularidades no ritmo cardíaco. Esse método permite interpretar a dinâmica do sistema nervoso autônomo e a variabilidade da frequência cardíaca [Ponsiglione et al. 2021].

O PC é construído plotando pares de intervalos RR consecutivos (RR_n, RR_{n+1}) em um plano cartesiano, gerando um gráfico de dispersão. A Figura 4 mostra os PCs de um registro normal e outro patológico, considerando segmentos de 10 min da FHR.

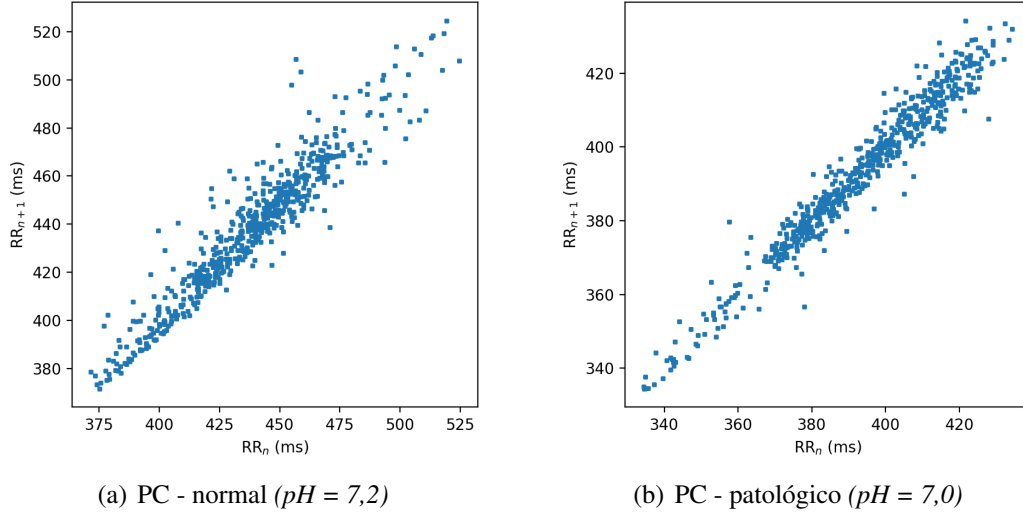


Figura 4. Gráficos de Poincaré (PC) referentes a um registro normal e a outro com hipóxia, com os intervalos RR expressos em milissegundos (ms).

Diferentemente do RP, o PC possui poucos parâmetros ajustáveis. Uma estratégia para gerar múltiplas imagens de PC a partir de um mesmo sinal da FHR é variar a defasagem (*lag*), conforme a Equação 3, capturando padrões em diferentes escalas temporais e aprimorando a precisão e robustez do diagnóstico [Goshvarpour et al. 2011].

$$\{(RR_i, RR_{i+k})\}_{k=1}^K \quad (3)$$

onde RR_i representa o intervalo RR no ponto i , e k a defasagem que varia de 1 até K , sendo K o máximo de escalas. Para cada valor de k , um par de pontos (RR_i, RR_{i+k}) é gerado, capturando a relação entre os intervalos RR em diferentes escalas temporais.

Ademais, salienta-se que a base de dados CTU-CHB não fornece os intervalos RR diretamente, mas sim a FHR. Portanto, neste trabalho, os intervalos RR foram estimados e calculados a partir da FHR para a construção dos PCs.

2.4. Rede Neural Convolutional

As Redes Neurais Convolucionais têm se destacado no campo do Aprendizado de Máquina (*Machine Learning*), particularmente no contexto do Aprendizado Profundo (*Deep Learning*), devido à sua capacidade de processar e extrair padrões complexos de dados, especialmente de imagens, o que impulsionou o seu sucesso em diversas aplicações [Li et al. 2021].

As CNNs processam dados bidimensionais, como imagens, por meio de camadas convolucionais que extraem automaticamente características hierárquicas. Sua arquitetura inclui camadas de convolução, que identificam padrões locais; camadas de *pooling*, que reduzem a dimensionalidade e preservam informações essenciais; e camadas totalmente conectadas, responsáveis pela classificação final [Ajit et al. 2020].

Desde sua introdução por Yann LeCun na década de 1990, as CNNs evoluíram significativamente. Contudo, apesar dos avanços, é importante frisar que ainda existem desafios relacionados à interpretabilidade das decisões das CNNs, especialmente em áreas críticas como os diagnósticos médicos. Uma vez que é fundamental assegurar não apenas a precisão dos diagnósticos, mas também a ética e a confiança no processo decisório [Salahuddin et al. 2022].

2.5. Avaliação de Desempenho

Para garantir maior robustez nos resultados, foi aplicada a validação cruzada em 10 dobras (*folds*), utilizando nove grupos para treinamento e validação, e um para teste em cada iteração. O processo foi repetido 10 vezes, e os resultados finais foram obtidos pela média das iterações. Além disso, para evitar vazamento de dados e garantir a integridade do treinamento, múltiplas representações gráficas de um mesmo sinal da FHR foram alocadas sempre na mesma dobra, prevenindo a superestimação do desempenho do modelo.

Seguindo a abordagem em [Zhao et al. 2019] e por se tratar de um problema de classificação binária, o desempenho do sistema foi avaliado por meio da matriz de confusão, considerando os parâmetros: Verdadeiro Positivo (VP), Falso Positivo (FP), Falso Negativo (FN) e Verdadeiro Negativo (VN). Sendo que os rótulos *Positivo* e *Negativo* representam, respectivamente, *fetos normais* e *com hipóxia*.

A partir da matriz de confusão, foram calculados cinco indicadores comumente utilizados para avaliar algoritmos de classificação: acurácia (*accuracy* - *Acc*), sensibilidade (*recall* ou *sensitivity*), especificidade (*specificity*), precisão (*precision*) e pontuação F1 (*F1-score*). Descritas, respectivamente, nas Equações 4, 5, 6, 7 e 8.

$$Acc = \frac{VP + VN}{VP + FP + VN + FN} \quad (4) \quad Especificidade = \frac{VN}{VN + FP} \quad (6)$$

$$Sensibilidade = \frac{VP}{VP + FN} \quad (5) \quad Precisão = \frac{VP}{VP + FP} \quad (7)$$

$$F1-score = 2 \cdot \frac{Precisão \cdot Sensibilidade}{Precisão + Sensibilidade} \quad (8)$$

A *Acc* indica a proporção total de acertos do modelo; a *Sensibilidade* avalia a capacidade de identificar corretamente fetos normais, e a *Especificidade* refere-se à detecção de fetos com hipóxia. Para uma avaliação mais abrangente, utilizou-se o *F1-score*, que combina *Precisão* e *Sensibilidade*, permitindo comparar melhor o desempenho obtido com as duas representações da FHR.

3. Resultados e Discussão

A abordagem proposta neste trabalho foi implementada em *Python* (versão 3.11.11) no ambiente *Google Colab*, escolhido por sua compatibilidade com bibliotecas populares e pelo acesso gratuito a Unidades de Processamento Gráfico (*Graphics Processing Units* - GPUs) NVIDIA T4 com 16GB de memória GDDR6, fator essencial para a aceleração do treinamento das redes neurais.

Os testes iniciaram com a seleção aleatória de 105 registros normais para garantir o balanceamento do modelo. Em seguida, os sinais de FHR foram pré-processados e

segmentados com base em janelas temporais, considerando as últimas amostras de cada registro de FHR, uma vez que os sinais mais próximos ao parto tendem a estar mais associados à hipóxia fetal [Chudáček et al. 2011]. Posteriormente, gerou-se as representações gráficas utilizadas no treinamento e teste das CNNs.

Para assegurar uma comparação justa, os cenários de teste foram configurados de modo que ambas as representações tivessem o mesmo número de imagens, ajustando-se individualmente os parâmetros de cada método. Convencionou-se a gerar 2.100 figuras, correspondentes a 10 imagens para cada sinal de FHR. Nos RPs, empregou-se $m = 2$, $\tau = 1$ e ε variando de 1 a 10, com incremento de 1. Já nos PCs, calculou-se os intervalos RR a partir da FHR e aplicou-se uma defasagem (*lag*) de 1 a 10, com incremento de 1.

As imagens foram rotuladas como normais ou patológicas, conforme pH dos registros. Em seguida, aplicou-se a validação cruzada em 10 dobras, em que, a cada iteração, 90% dos dados foram utilizados para treinamento e validação (sendo 80% para treinamento e 20% para validação), enquanto os 10% restantes foram reservados para o teste.

A arquitetura da Rede Neural Convolutacional (CNN) implementada neste trabalho, detalhada na Tabela 2, é composta por quatro camadas convolucionais seguidas de normalização em lote (*batch normalization*), com um tamanho de lote de 64, ativação *ReLU* e *MaxPooling*. Os parâmetros das camadas convolucionais, incluindo filtros e tamanhos, também são indicados na referida tabela. Após a extração de características, os dados são achatados e passados por três camadas totalmente conectadas (*fully connected*). As dimensões dos Mapas de Características (*Feature Maps*) são apresentadas na última coluna da Tabela 2. Para prevenir sobreajuste (*overfitting*), é aplicado um *dropout* de 50%. Por fim, a saída da rede possui dois neurônios, correspondendo às classes do problema.

Tabela 2. Detalhes arquiteturais da Rede Neural Convolutacional (CNN) proposta.

Camada*	Tipo	Tamanho	Entrada			Saída MC
			Filtros	Stride	Padding	
1	Entrada	—	—	—	—	$224 \times 224 \times 3$
2	Convolução	5×5	16	1	2	$224 \times 224 \times 16$
3	MaxPooling	2×2	—	2	—	$112 \times 112 \times 16$
4	Convolução	3×3	32	1	1	$112 \times 112 \times 32$
5	MaxPooling	2×2	—	2	—	$56 \times 56 \times 32$
6	Convolução	3×3	64	1	1	$56 \times 56 \times 64$
7	MaxPooling	2×2	—	2	—	$28 \times 28 \times 64$
8	Convolução	3×3	128	1	1	$28 \times 28 \times 128$
9	MaxPooling	2×2	—	2	—	$14 \times 14 \times 128$
10	FC	512	—	—	—	512×1
11	FC	128	—	—	—	128×1
12	FC	2	—	—	—	2×1
13	Saída	—	—	—	—	2×1

* As camadas de normalização e ReLU, após cada camada de convolução, e as camadas de *dropout* entre as três camadas totalmente conectadas (FC) não foram incluídas acima pois não modificam os Mapas de Características (MC) de saída.

Este modelo foi adaptado, a partir da abordagem proposta em [Zhao et al. 2019], para receber entradas de 224×224 , uma resolução amplamente utilizada na literatura, possibilitando futuramente a realização de testes com modelos pré-treinados por meio de transferência de aprendizado (*transfer learning*).

Para cada representação, o modelo foi treinado por 10 épocas utilizando o otimizador *Adam*, devido à sua eficiência na adaptação dos pesos e rápida convergência, com uma taxa de aprendizado de 1×10^{-3} , e como função de perda adotou-se a *CrossEntropyLoss*.

Os resultados das CNNs treinadas com as representações RP e PC são apresentados na Figura 5. A análise do desempenho das duas representações revela diferenças significativas na acurácia e na capacidade de generalização, especialmente, em relação à escolha do tamanho do segmentos. O RP apresenta melhor desempenho em segmentos de 15 min, enquanto o PC requer segmentos mais longos, acima de 30 min, para alcançar resultados equivalentes.

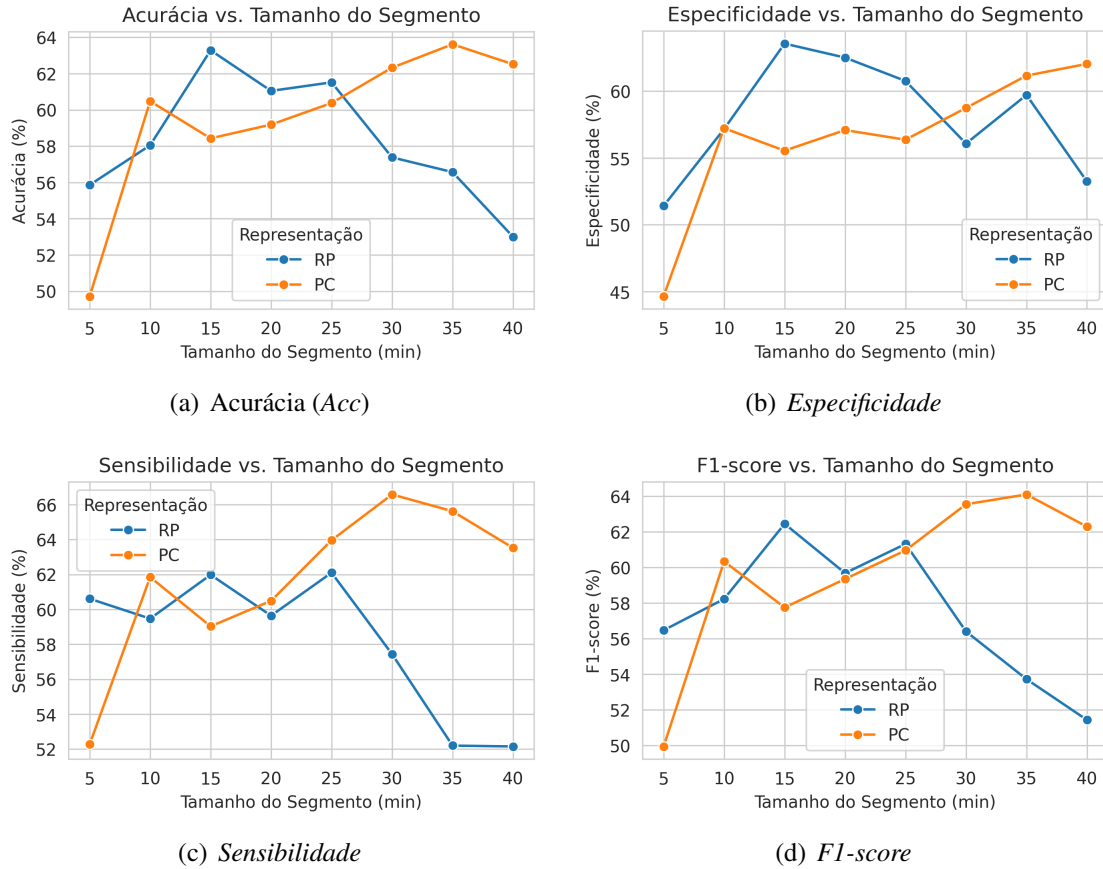


Figura 5. Resultados obtidos utilizando o Gráfico de Recorrência (RP) e o Gráfico de Poincaré (PC), aplicados a segmentos da frequência cardíaca fetal (FHR) com diferentes durações em minutos (min).

Essa diferença é ainda mais evidente no *F1-score*, na Figura 5(d). O RP perde desempenho em janelas longas, possivelmente em função da degradação da estrutura de recorrência. Ao passo que o PC mantém estabilidade superior, indicando maior capacidade de capturar os padrões dinâmicos da FHR ao longo do tempo. Em suma, embora o PC apresente bons resultados em seu melhor cenário, uma análise global revela que o

RP apresentou desempenho superior em múltiplas condições, destacando-se como uma representação mais eficaz na captura de padrões temporais complexos.

A Tabela 3 compara os melhores resultados obtidos neste estudo, considerando o *F1-score*, com outras abordagens de detecção de hipóxia fetal a partir da FHR empregando CNNs. Os dados apresentados foram adaptados de [Xiao et al. 2022], que implementou as técnicas listadas e conduziu experimentos na mesma base de dados utilizada neste trabalho, considerando segmentos de 20 min.

Tabela 3. Comparação com outras abordagens que empregaram Rede Neural Convolutacional (CNN).

Autor	Método	Desempenho (%)	
		Sensibilidade	Especificidade
[Liang and Li 2021]*	CNN	33,48	77,46
[Li et al. 2018]*	CNN	52,12	74,93
[Xiao et al. 2022]*	Multiscale CNN-BiLSTM	66,29	65,84
este trabalho**	RP + CNN	61,98 ± 10,9	63,58 ± 11,2
este trabalho	PC + CNN	65,62 ± 6,6	61,17 ± 12,3

* Resultados descritos em [Xiao et al. 2022].

** Resultados obtidos com a adaptação do modelo descrito em [Zhao et al. 2019].

Observa-se que as abordagens analisadas neste trabalho obtiveram resultados bem próximos aos encontrados em [Xiao et al. 2022], ao combinar redes convolucionais e recorrentes para essa tarefa. Em comparação com os métodos baseados exclusivamente em CNNs propostos em [Liang and Li 2021] e [Li et al. 2018], este trabalho apresentou *sensibilidade* superior, embora tenha obtido *especificidade* inferior. Esses resultados reforçam a importância da escolha da representação da série temporal na classificação da hipóxia fetal, evidenciando que abordagens como RP e PC, ao capturar dinâmicas não lineares da FHR, podem melhorar a detecção de padrões críticos em comparação a métodos baseados unicamente em CNNs.

4. Conclusão

A detecção precoce da hipóxia fetal é crucial para prevenir complicações graves, como danos neurológicos permanentes - incluindo atraso no desenvolvimento, paralisia cerebral, epilepsia e déficits cognitivos - ou até mesmo a morte fetal [Muccini et al. 2022]. A análise dos sinais de FHR possibilita o desenvolvimento de modelos preditivos mais precisos, auxiliando na tomada de decisões clínicas em tempo real e melhorando a segurança materno-fetal.

Portanto, esta pesquisa explorou o uso de CNNs para a detecção de hipóxia fetal, empregando duas representações gráficas – RP e PC – de séries temporais da FHR registradas por meio do CTG. O objetivo foi avaliar a eficácia de cada abordagem na classificação de padrões associados à hipóxia fetal. Visando garantir a reprodutibilidade e apoiar pesquisas futuras, o código-fonte deste trabalho encontra-se disponível publicamente em um repositório digital¹.

¹Hospedado em <https://github.com/andrecoimbra/CTG-RP-PC>

Os resultados demonstraram que os RP alcançaram um desempenho superior na detecção da hipóxia fetal em segmentos de 15 min, enquanto o PC apresentou maior estabilidade para segmentos acima de 30 min. Entretanto, de uma forma geral, os resultados indicaram que a estrutura das imagens do RP é mais eficaz na captura de características relevantes da FHR para a detecção de hipóxia fetal. Além disso, é importante destacar que, em situações críticas, onde a duração do registro CTG é limitada, o RP se mostra mais vantajoso por sua capacidade de capturar padrões relevantes em registros mais curtos.

Considerando os avanços recentes, pesquisas futuras deverão avaliar arquiteturas baseadas em *Transformers* para análise da FHR, uma vez que esses modelos demonstram eficácia na captura de dependências de longo alcance e na identificação de padrões complexos, potencializando a detecção de hipóxia fetal ao reconhecer interações temporais sutis que métodos tradicionais não conseguem captar [Anwar et al. 2024]. Ademais, recomenda-se explorar novas representações de séries temporais e empregar redes pré-treinadas — como ResNet, EfficientNet e similares — visando aprimorar o desempenho da classificação.

Por fim, espera-se que este estudo contribua para o avanço das técnicas de diagnóstico de hipóxia fetal, fornecendo bases para o desenvolvimento de ferramentas mais precisas e automatizadas para a prática obstétrica, auxiliando na tomada de decisões clínicas e na redução de intervenções desnecessárias.

5. Agradecimentos

Este trabalho foi apoiado pelo Centro de Competência em Tecnologias Imersivas (AKCIT) e pelo Centro de Excelência em Inteligência Artificial (CEIA), como parte do projeto de pesquisa SEnsoriamento Multimodal Avançado (SEMA), e pela Fundação de Amparo à Pesquisa do Estado de Goiás (FAPEG).

Referências

- Ajit, A., Acharya, K., and Samanta, A. (2020). A review of convolutional neural networks. In *2020 international conference on emerging trends in information technology and engineering (ic-ETITE)*, pages 1–5. IEEE.
- Anwar, A., Khalifa, Y., Coyle, J. L., and Sejdic, E. (2024). Transformers in biosignal analysis: A review. *Information Fusion*, page 102697.
- Chudáček, V., Spilka, J., Burša, M., Janků, P., Hruban, L., Huptych, M., and Lhotská, L. (2014). Open access intrapartum ctg database. *BMC pregnancy and childbirth*, 14:1–12.
- Chudáček, V., Spilka, J., Lhotská, L., Janků, P., Koucký, M., Huptych, M., and Burša, M. (2011). Assessment of features for automatic ctg analysis based on expert annotation. In *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pages 6051–6054. IEEE.
- Cömert, Z., Kocamaz, A. F., and Subha, V. (2018). Prognostic model based on image-based time-frequency features and genetic algorithm for fetal hypoxia assessment. *Computers in biology and medicine*, 99:85–97.
- Eckmann, J.-P., Kamphorst, S. O., and Ruelle, D. (1987). Recurrence plots of dynamical systems. *Europhysics Letters*, 4(9):973–977.

- Faouzi, J. (2017-2021). `pyts.image.recurrenceplot` - `pyts 0.13.0` documentation. <https://pyts.readthedocs.io/en/latest/generated/pyts.image.RecurrencePlot.html>. Acesso em: 07 de mar. de 2025.
- Goshvarpour, A., Goshvarpour, A., and Rahati, S. (2011). Analysis of lagged poincare plots in heart rate signals during meditation. *Digital Signal Processing*, 21(2):208–214.
- Gunaratne, S. A., Panditharatne, S. D., and Chandrabaran, E. (2022). Prediction of neonatal acidosis based on the type of fetal hypoxia observed on the cardiotocograph (ctg). *European Journal of Medical and Health Sciences*, 4(2):8–18.
- Kanagal, D. V. and Praveen, B. (2022). Intrapartum fetal monitoring and its correlation with umbilical cord blood ph and early neonatal outcome: A prospective cohort study. *Journal of South Asian Federation of Obstetrics and Gynaecology*, 14(1):63–67.
- Li, J., Chen, Z.-Z., Huang, L., Fang, M., Li, B., Fu, X., Wang, H., and Zhao, Q. (2018). Automatic classification of fetal heart rate based on convolutional neural network. *IEEE Internet of Things Journal*, 6(2):1394–1401.
- Li, Z., Liu, F., Yang, W., Peng, S., and Zhou, J. (2021). A survey of convolutional neural networks: analysis, applications, and prospects. *IEEE transactions on neural networks and learning systems*, 33(12):6999–7019.
- Liang, S. and Li, Q. (2021). Automatic evaluation of fetal heart rate based on deep learning. In *2021 2nd information communication technologies conference (ICTC)*, pages 235–240. IEEE.
- Muccini, A. M., Tran, N. T., Hale, N., McKenzie, M., Snow, R. J., Walker, D. W., and Ellery, S. J. (2022). The effects of in utero fetal hypoxia and creatine treatment on mitochondrial function in the late gestation fetal sheep brain. *Oxidative Medicine and Cellular Longevity*, 2022(1):3255296.
- Ponsiglione, A. M., Cosentino, C., Cesarelli, G., Amato, F., and Romano, M. (2021). A comprehensive review of techniques for processing and analyzing fetal heart rate signals. *Sensors*, 21(18):6136.
- Romano, M., Faiella, G., Bifulco, P., D’Addio, G., Clemente, F., and Cesarelli, M. (2014). Outliers detection and processing in ctg monitoring (2014) xiii mediterranean conference on medical and biological engineering and computing 2013.
- Salahuddin, Z., Woodruff, H. C., Chatterjee, A., and Lambin, P. (2022). Transparency of deep neural networks for medical image analysis: A review of interpretability methods. *Computers in biology and medicine*, 140:105111.
- Silva, B., Ribeiro, M., and Henriques, T. S. (2022). Compression of different time series representations in asphyxia detection. In *2022 E-Health and Bioengineering Conference (EHB)*, pages 1–5. IEEE.
- Xiao, Y., Lu, Y., Liu, M., Zeng, R., and Bai, J. (2022). A deep feature fusion network for fetal state assessment. *Frontiers in Physiology*, 13:969052.
- Zhao, Z., Zhang, Y., Comert, Z., and Deng, Y. (2019). Computer-aided diagnosis system of fetal hypoxia incorporating recurrence plot with convolutional neural network. *Frontiers in physiology*, 10:255.