

A Aplicação do Aprendizado Profundo na Prevenção e Diagnóstico de Diabetes Mellitus Tipo 2 da Especialização em Informática em Saúde

The Application of Deep Learning in the Prevention and Diagnosis of Type 2 Diabetes Mellitus from the Specialization in Health Informatics

Allan Calixto ^{1*}, Thiago Bulhões da Silva Costa ²

¹Bacharel em Sistemas de Informações, Especialista em Gestão em Saúde. São Paulo – SP, Brasil.

²Professor Doutor. Universidade Aberta do Brasil, Universidade Federal de São Paulo - UNIFESP, São Paulo (SP), Brasil.

RESUMO

Este trabalho analisou a aplicação de redes neurais profundas no diagnóstico precoce e na previsão de complicações do Diabetes Mellitus Tipo 2 (DM2). O estudo teve como objetivo principal investigar como essas tecnologias contribuem para melhorar a acurácia diagnóstica e preditiva em relação a métodos tradicionais. Foi utilizada uma revisão de literatura integrativa, abrangendo artigos publicados entre 2019 e 2024 em bases como PubMed, IEEE Xplore, ScienceDirect e Google Scholar. A análise incluiu modelos como LSTM, CNN e RNN, destacando seus desempenhos superiores em métricas como acurácia (até 85%) e área sob a curva (AUC) (até 0,98). Os resultados evidenciaram que as redes neurais profundas permitem previsões mais personalizadas, identificando trajetórias de controle glicêmico e categorizando pacientes em grupos de risco. Com isto, a integração de dados genômicos, tabulares e clínicos mostrou-se essencial para a personalização do manejo clínico. Entretanto, foram identificadas limitações, como a dependência de grandes volumes de dados e o custo computacional elevado, que podem restringir a adoção em larga escala. Concluiu-se que o aprendizado profundo é uma ferramenta promissora na gestão do DM2, promovendo avanços significativos na medicina de precisão. Futuras pesquisas devem focar na otimização dos modelos e na ampliação das fontes de dados para maior acessibilidade e aplicabilidade prática.

Palavras-chave: Aprendizado Profundo, Diabetes Mellitus Tipo 2, Diagnóstico Preditivo, Medicina de Precisão, Análise de Dados Clínicos

Recebido: 11 de janeiro de 2025

Aceito: 25 de abril de 2025

* alancallixto@hotmail.com

ABSTRACT

This study analyzed the application of deep neural networks in the early diagnosis and prediction of complications for Type 2 Diabetes Mellitus (T2DM). The primary objective was to investigate how these technologies contribute to improving diagnostic and predictive accuracy compared to traditional methods. An integrative literature review was conducted, covering articles published between 2019 and 2024 from databases such as PubMed, IEEE Xplore, ScienceDirect, and Google Scholar. The analysis included models like LSTM, CNN, and RNN, highlighting their superior performance with metrics such as accuracy (up to 85%) and area under the curve (AUC) (up to 0.98). The results demonstrated that deep neural networks enable more personalized predictions by identifying glycemic control trajectories and categorizing patients into risk groups. The integration of genomic, tabular, and clinical data proved essential for customizing clinical management. However, limitations were identified, including the dependency on large data volumes and high computational costs, which may restrict large-scale adoption. It was concluded that deep learning is a promising tool for T2DM management, driving significant advances in precision medicine. Future research should focus on model optimization and expanding data sources to improve accessibility and practical applicability.

Keywords: Deep Learning, Type 2 Diabetes Mellitus, Predictive Diagnostics, Precision Medicine, Clinical Data Analysis

Introdução

O Diabetes Mellitus Tipo 2 (DM2) é uma condição metabólica caracterizada por hiperglicemia crônica, resultante da resistência à insulina ou da deficiência na sua produção, afetando milhões de pessoas em todo o mundo (Srinivasu et al., 2022). Estudos indicam que o DM2 afeta cerca de 537 milhões de indivíduos globalmente, com projeções de aumento para 552 milhões até 2030 (Lavikainen et al., 2023; Srinivasu et al., 2022). O impacto dessa doença não se limita à saúde dos pacientes, mas também representa um enorme custo financeiro para sistemas de saúde e famílias, devido aos custos relacionados ao tratamento e ao manejo de suas complicações (Liu et al., 2019). Complicações graves, como neuropatia diabética, doenças cardiovasculares e insuficiência renal, são frequentes entre os pacientes com DM2, especialmente quando o diagnóstico e o tratamento não são realizados precocemente (Liu et al., 2019; Yun et al., 2024). Nesse sentido, estratégias de prevenção e diagnóstico precoce tornam-se indispensáveis para reduzir a progressão da doença e minimizar os custos sociais e econômicos associados (Lai et al., 2024).

Os métodos convencionais de diagnóstico e previsão do DM2, possuem limitações significativas em termos de precisão, especialmente em populações heterogêneas (Liu et al., 2019; Yun et al., 2024).

Essas abordagens frequentemente falham em personalizar o cuidado, comprometendo o prognóstico e o manejo dos pacientes (Lavikainen et al., 2023). Tecnologias emergentes, como a inteligência artificial (IA), têm demonstrado grande potencial para superar essas deficiências, possibilitando análises mais complexas e preditivas (Lai et al., 2024). Redes neurais profundas, como as redes convolucionais (CNNs) e de memória de longo prazo (LSTM), destacam-se pela capacidade de processar grandes volumes de dados clínicos e identificar padrões que escapam aos métodos tradicionais (Yun et al., 2024). Essas tecnologias não apenas aumentam a precisão do diagnóstico, mas também oferecem oportunidades para prever complicações como a nefropatia diabética, promovendo melhorias na qualidade do atendimento (Yun et al., 2024; Srinivasu et al., 2022).

O aprendizado profundo, um ramo avançado da inteligência artificial, baseia-se em redes multicamadas que imitam, de forma simplificada, o funcionamento do cérebro humano para processar e interpretar dados complexos (Lai et al., 2024). Nos últimos anos, sua adoção no campo médico tem crescido, revolucionando métodos tradicionais de diagnóstico e previsão de doenças (Lai et al., 2024). No caso do Diabetes Mellitus Tipo 2, redes como as CNNs (Redes Neurais Convolucionais) e LSTM (Redes de Memória de Longo Prazo) demonstram eficiência em tarefas de análise de dados clínicos e predição de eventos de curto e longo prazo, superando limitações de técnicas preexistentes (Lai et al., 2024).

Estudos também destacam que esses modelos têm potencial para identificar padrões ocultos em dados de saúde, permitindo intervenções mais precisas e personalizadas (Lavikainen et al., 2023). Em particular, a previsão da neuropatia sensorio-motora distal (DSPN), uma complicação comum do diabetes, pode ser melhorada, possibilitando intervenções precoces e redução de complicações graves, como úlceras nos pés e amputações (Lai et al., 2024).

A integração de redes neurais profundas com dados genômicos e clínicos amplia ainda mais as possibilidades no diagnóstico e manejo do DM2. Modelos baseados em redes recorrentes, como RNNs, têm mostrado a capacidade de processar dados longitudinais e

genéticos para prever doenças futuras, como o DM2 e suas complicações (Srinivasu et al., 2022). O uso de aprendizado profundo combinado com avanços em tecnologia genômica tem pavimentado o caminho para previsões mais acuradas, destacando a eficiência de modelos LSTM, que alcançam resultados superiores em comparação com métodos tradicionais, como máquinas de vetores de suporte (Yun et al., 2024; Srinivasu et al., 2022).

Essas inovações são especialmente relevantes diante do aumento global de casos de diabetes e da necessidade de alocar recursos médicos de maneira eficiente. Modelos preditivos de alto desempenho permitem identificar subgrupos de pacientes que requerem cuidados intensivos, otimizando a gestão clínica e promovendo economia de recursos para sistemas de saúde (Lavikainen et al., 2023).

Com base nesse panorama, este trabalho tem como objetivo geral analisar como a aplicação de redes neurais profundas tem influenciado o diagnóstico precoce e a previsão de complicações associadas ao Diabetes Mellitus Tipo 2, a partir de uma revisão da literatura existente. A pergunta de pesquisa que orienta este estudo é: O uso de redes neurais profundas tem contribuído para melhorar a acurácia no diagnóstico precoce e na previsão de complicações do Diabetes Mellitus Tipo 2? Além disso, busca-se avaliar as limitações e os desafios inerentes ao uso dessas redes no diagnóstico e na prevenção dessa condição, com o intuito de identificar barreiras e apontar direções para futuras pesquisas que visem o aprimoramento dessas tecnologias na prática clínica.

A relevância social desse tema é marcado pelo aumento exponencial dos casos de DM2, a aplicação de tecnologias avançadas, como o aprendizado profundo, apresenta-se como uma solução promissora. Essa abordagem pode permitir diagnósticos mais precoces e precisos, além de otimizar recursos e promover intervenções preventivas eficazes (Yun et al., 2024). Sob a perspectiva acadêmica, o desenvolvimento de estudos que integram aprendizado profundo e saúde reforça a importância da modernização no campo da informática em saúde, além de proporcionar contribuições relevantes para o avanço do conhecimento e práticas mais eficientes. Assim, este estudo dialoga diretamente com as demandas sociais e científicas, oferecendo subsídios para a transformação dos cuidados em saúde.

Método

O presente trabalho utiliza uma revisão de literatura integrativa como abordagem metodológica principal, com o objetivo de analisar como as redes neurais profundas têm sido aplicadas no diagnóstico precoce e na previsão de complicações associadas ao Diabetes Mellitus Tipo 2. Para isso, foram realizadas buscas sistemáticas em bases de dados reconhecidas nas áreas médica e tecnológica, incluindo PubMed, IEEE Xplore, ScienceDirect e Google Scholar, devido à sua abrangência e relevância acadêmica. As buscas foram realizadas utilizando combinações de palavras-chave como "deep learning", "diabetes type 2", "neural networks", "biomarkers" e "diabetes complications", associadas a operadores booleanos (AND e OR) para refinar os resultados.

Os critérios de inclusão envolveram a seleção de artigos originais publicados entre 2019 e 2024, garantindo a atualidade dos dados analisados. Apenas estudos com aplicações práticas de redes neurais profundas no diagnóstico e na previsão de complicações do DM2 foram considerados. Revisões de literatura e estudos que não apresentassem resultados aplicáveis diretamente à prática clínica foram excluídos.

Os dados coletados foram analisados qualitativamente, com foco na identificação de padrões e tendências na literatura. A análise destacou arquiteturas de redes como LSTM, RNN e CNN, frequentemente utilizadas em estudos recentes para processar dados clínicos e genômicos. Além disso, foram examinadas métricas de desempenho, como acurácia e área sob a curva ROC (AUC), e sua relação com os objetivos dos estudos analisados.

O uso do modelo PICO para formular perguntas de pesquisa e refinar buscas bibliográficas destaca a importância de uma abordagem estruturada para revisões integrativas (SANTOS; PIMENTA; NOBRE, 2007). Os descritores em ciências da saúde (DeCS) foram fundamentais para padronizar os termos de busca, ampliando a recuperação de estudos relevantes (BIREME, 2024). O CDHI.br exemplifica a aplicação prática de tecnologias digitais em saúde no Brasil, conectando a pesquisa ao contexto nacional de saúde digital (TENÓRIO; SOUSA; PISA, 2023). Além disso, fontes sobre indicadores sociais e de saúde pública, como Dias, Freitas e Briz (2007), Kligerman et al. (2007) e Sobral e Freitas (2010), situam a relevância do estudo no âmbito de sistemas de saúde e determinantes sociais. Essas bases, aliadas às inovações tecnológicas, integram ciência e prática clínica, contribuindo para o avanço da medicina de precisão.

Resultado

A revisão da literatura demonstrou o crescente uso de redes neurais profundas no diagnóstico precoce e na previsão de complicações associadas ao Diabetes Mellitus Tipo 2 (DM2). Estudos recentes destacaram o desempenho superior de arquiteturas como LSTM, CNN e GRU em comparação com métodos tradicionais, especialmente em termos de acurácia e AUC (Faruqui et al., 2019; Ljubic et al., 2020; Yun et al., 2024). A integração de múltiplas fontes de dados, incluindo variáveis clínicas, genômicas e tabulares, foi uma constante nos estudos revisados. Esses modelos mostraram-se eficazes em personalizar o manejo clínico e prever complicações específicas do DM2, como neuropatia, doenças cardiovasculares e nefropatia (Srinivasu et al., 2022; Lai et al., 2024). O Quadro 1 apresenta uma síntese dos principais achados, incluindo as bases de dados, as arquiteturas utilizadas e os resultados observados em cada estudo.

Quadro 1 – Comparativa Dos Artigos Sobre Deep Learning No DM2.

Artigo	Arquitetura de Redes Utilizadas	Base de Dados	Resultados	Contribuição	CDHI.br
Development of a Deep Learning Model for Dynamic Forecasting of Blood Glucose Level for Type 2 Diabetes Mellitus	LSTM, RNN	Dados de estilo de vida monitorados de 10 pacientes, incluindo ingestão alimentar (calorias e macronutrientes), atividade física (calorias queimadas), peso corporal e glicemia diária, coletados ao longo de 6 meses.	Acurácia de 85% para previsão de glicemia	Previsão dinâmica de glicemia em curto e longo prazo	S.1.4 - Diagnóstico Digital
Predicting Complications of Diabetes Mellitus Using Advanced Machine Learning Algorithms	LSTM, GRU	Dados do Healthcare Cost and Utilization Project (HCUP), incluindo registros eletrônicos de saúde (diagnósticos e internações hospitalares) de mais de 1,9 milhão de pacientes na Califórnia, coletados entre 2003 e 2011.	AUC > 0.85 para complicações do DM2	Previsão de complicações como neuropatia e doenças cardiovasculares	S.4.3 - Inteligência Artificial e Análise Preditiva
Longitudinal Artificial Intelligence-Based Deep Learning Models for Diagnosis and Prediction of Polyneuropathy in Diabetes and Prediabetes	CNN, LSTM	Clinical Toronto Neuropathy Score (TCNS)	AUC de 0.98 para diagnóstico de DSPN	Diagnóstico precoce e previsão de neuropatia diabética	S.1.3 - Diagnóstico Digital com Base em Inteligência Artificial.

Application of Three Statistical Models for Predicting the Risk of Diabetes	Redes Neurais	Dados clínicos e demográficos de 4.177 indivíduos chineses, incluindo idade, perfil lipídico (triglicerídeos, colesterol), glicemia de jejum, hipertensão e consumo de álcool, coletados em um estudo populacional para análise de fatores de risco para diabetes tipo 2.	AUC de 0.780, precisão de 91.2%	Comparação de redes neurais com métodos tradicionais	S.4.2 - Suporte à Decisão Clínica.
Data-Driven Identification of Long-Term Glycemia Clusters and Their Individualized Predictors in Finnish Patients with Type 2 Diabetes	Redes Neurais	Prontuários eletrônicos de 9.631 pacientes finlandeses	AUC de 0.91, precisão de 85%	Predição de controle glicêmico a longo prazo	S.4.3 – Inteligência Artificial e Análise Preditiva
Using Recurrent Neural Networks for Predicting Type 2 Diabetes from Genomic and Tabular Data	RNN, LSTM, GRU	Sequências genômicas extraídas de DNA e dados tabulares do conjunto PIMA (idade, glicose, IMC, pressão arterial, histórico familiar), processados para prever padrões genéticos e clínicos relacionados ao diabetes tipo 2.	Acurácia entre 80% e 90% na previsão de diabetes tipo 2 usando dados genômicos e tabulares, com identificação eficiente de padrões genéticos e correlação robusta com fatores clínicos.	Identificação de padrões genéticos e tabulares para diagnóstico	S.3.2 - Inteligência Artificial para Diagnóstico e Previsão
Construction of Risk Prediction Model of Type 2 Diabetic Kidney Disease Based on Deep Learning	LSTM	Dados clínicos longitudinais de 6.040 pacientes com diabetes tipo 2, incluindo variabilidade de HbA1c, pressão arterial sistólica e de pulso, coletados ao longo de 7 anos em registros médicos.	AUC de 0.83, precisão de 83%	Modelo preditivo de risco de doença renal diabética	S.4.2 – Inteligência Artificial Aplicada ao Diagnóstico e Risco.

Discussão

Os resultados analisados reforçam o impacto transformador das redes neurais profundas na prática clínica, com modelos como LSTM e GRU superando métodos tradicionais em precisão preditiva (Faruqui et al., 2019; Ljubic et al., 2020). Por exemplo, redes LSTM atingiram acurácia de até 85% em previsões glicêmicas (Faruqui et al., 2019), enquanto GRU e LSTM demonstraram desempenho robusto em prever complicações, como neuropatia e doenças cardiovasculares, com AUC superior a 0,85 (Ljubic et al., 2020). Apesar da superioridade em cenários com grandes volumes de dados,

abordagens tradicionais, como a regressão logística, ainda são viáveis em situações de recursos limitados (Yun et al., 2024). Essa dualidade sugere que o contexto clínico e a disponibilidade de dados são determinantes na escolha da técnica ideal.

A personalização foi outro aspecto de destaque. Lavikainen et al. (2023) demonstraram que redes neurais podem categorizar pacientes em diferentes trajetórias de risco glicêmico a longo prazo. Em contrapartida, Srinivasu et al. (2022) integraram dados genômicos e tabulares para prever complicações específicas do DM2, como nefropatia, mostrando a flexibilidade dos modelos em lidar com variáveis de diferentes origens.

A combinação de múltiplas arquiteturas também se mostrou promissora. Lai et al. (2024) relataram que a integração de CNNs e LSTM melhora a análise de escores neuropáticos, atingindo AUC de 0,98 no diagnóstico precoce de neuropatia distal sensorio-motora. Por outro lado, Yun et al. (2024) priorizaram a análise da variabilidade glicêmica para prever doenças renais, reforçando a adaptabilidade dos modelos.

A necessidade de grandes volumes de dados padronizados e de alta qualidade foi destacada por Faruqui et al. (2019) e Ljubic et al. (2020) como um fator limitante para a implementação generalizada. Além disso, o custo computacional elevado dificulta a adoção em contextos de baixa infraestrutura tecnológica (Faruqui et al., 2019; Yun et al., 2024). Outra questão é a heterogeneidade nas métricas de avaliação. Enquanto AUC foi amplamente utilizada, estudos como o de Srinivasu et al. (2022) também enfatizaram métricas como F1-Score e MCC, indicando a necessidade de uma padronização para facilitar a comparação de resultados.

Em síntese, as redes neurais profundas têm demonstrado potencial para transformar o manejo do DM2. Estudos futuros devem concentrar-se na otimização de algoritmos, redução de custos computacionais e ampliação das fontes de dados heterogêneos, garantindo maior acessibilidade e equidade na aplicação dessas tecnologias (Lavikainen et al., 2023; Lai et al., 2024).

Considerações finais

O presente estudo analisou o impacto das redes neurais profundas no diagnóstico precoce e na previsão de complicações do Diabetes Mellitus Tipo 2 (DM2), a partir de uma revisão de literatura integrativa. A pesquisa incluiu artigos publicados entre 2019 e 2024, com dados extraídos de bases renomadas como PubMed, IEEE Xplore,

ScienceDirect e Google Scholar. Por meio da análise de modelos avançados, como LSTM, CNN e RNN, o trabalho identificou melhorias significativas nas métricas de acurácia e AUC, bem como a superioridade dessas arquiteturas em comparação com métodos tradicionais. Essa abordagem permitiu responder à questão norteadora: Como o uso de redes neurais profundas tem contribuído para melhorar a acurácia no diagnóstico precoce e na previsão de complicações do Diabetes Mellitus Tipo 2?

Os resultados alcançados indicam que as redes neurais profundas apresentam notável desempenho na predição e diagnóstico do DM2, atingindo acurácia de até 85% e AUC de 0,98 em alguns cenários. Essas tecnologias permitem, ainda, a personalização do manejo clínico ao identificar trajetórias de risco e categorizar pacientes de acordo com necessidades específicas, promovendo intervenções mais eficazes. Além disso, a integração de dados genômicos, tabulares e clínicos ampliou a precisão dos modelos, consolidando o aprendizado profundo como uma ferramenta valiosa na prática clínica. Entretanto, o estudo também destacou algumas limitações, como a dependência de grandes volumes de dados e o alto custo computacional, que podem limitar sua aplicação em ambientes com poucos recursos tecnológicos. As contribuições deste trabalho estão relacionadas ao avanço do conhecimento sobre o uso de aprendizado profundo no manejo do DM2, consolidando evidências de que essas tecnologias podem transformar a prática clínica. Além de destacar a superioridade dessas redes em relação a métodos tradicionais, o estudo identificou desafios específicos, como a necessidade de padronização de dados e maior acessibilidade a recursos computacionais. Essas observações reforçam a importância da interdisciplinaridade entre informática e saúde para aprimorar diagnósticos e intervenções.

Para trabalhos futuros, sugere-se a exploração de arquiteturas híbridas, combinando diferentes modelos de redes neurais profundas para maximizar a eficiência preditiva e o processamento de dados heterogêneos. Com isto, seria relevante ampliar a base de dados com informações demográficas e sociais, o que poderia enriquecer a personalização do tratamento. Pesquisas voltadas para a redução do custo computacional e a otimização de algoritmos podem contribuir para a democratização do uso dessas tecnologias em cenários clínicos diversificados. Assim, o aprendizado profundo continua sendo uma promissora área de pesquisa, com potencial de impactar a saúde pública e a gestão do DM2.

REFERÊNCIAS

1. SANTOS, Cristina Mamédio da Costa; PIMENTA, Cibele Andrucio de Mattos; NOBRE, Moacyr Roberto Cuce. A estratégia PICO para a construção da pergunta de pesquisa e busca de evidências. *Revista latino-americana de enfermagem*, v. 15, p. 508-511, 2007. <https://doi.org/10.1590/S0104-11692007000300023>. Acesso em: 15 out. 2024.
2. Descritores em Ciências da Saúde: DeCS 2024. São Paulo: BIREME / OPAS / OMS, 2024. Disponível em: <http://decs.bvsalud.org/>. Acesso em: 14 out. 2024.
3. Tenório JM, Sousa FS, Pisa IT. Classificação de intervenções, aplicações e serviços em saúde digital para o contexto brasileiro (CDHI.br). São Paulo: 2023. Licença: CC BY-NC-SA 4.0 DEED. Disponível em <https://cdhi.saude360.app.br> Acesso em: 14 out. 2024.
4. DIAS, C. M.; FREITAS, M.; BRIZ, T. Indicadores de saúde: uma visão de saúde pública, com interesse em medicina geral e familiar. *Revista Portuguesa de Medicina Geral e Familiar*, Lisboa, v. 23, n. 4, p. 439-450, jul. 2007. Disponível em: <<http://www.rpmgf.pt/ojs/index.php/rpmgf/article/view/10388/10124>>. Acesso em: 04 ago. 2021.
5. KLIGERMAN, D. C. et al. Sistemas de indicadores de saúde e ambiente em instituições de saúde. *Ciência & Saúde Coletiva*, Rio de Janeiro, v. 12, n. 1, p. 199- 211, jan./mar. 2007. Disponível em: <<http://www.scielo.br/pdf/csc/v12n1/19.pdf>>. Acesso em: 04 ago. 2021.
6. SANTAGADA, S. Indicadores sociais: contexto social e breve histórico. *Indicadores Econômicos FEE*, Porto Alegre, v. 20, n. 4, p. 245-255, 1993. Disponível em: <<https://revistas.fee.tche.br/index.php/indicadores/article/view/758/1013>>. Acesso em: 01 ago. 2021.
7. SANTOS-FILHO, S. B. Perspectivas da avaliação na Política Nacional de Humanização em Saúde: aspectos conceituais e metodológicos. *Ciência & Saúde Coletiva*, Rio de Janeiro, v. 12, n. 4, p. 999-1010, jul./ago. 2007. Disponível em: <<http://www.scielo.br/pdf/csc/v12n4/18.pdf>>. Acesso em: 01 ago. 2021.

8. SOBRAL, A.; FREITAS, C. M. de. Modelo de organização de indicadores para operacionalização dos determinantes socioambientais da saúde. *Saúde e Sociedade*, São Paulo, v. 19, n. 1, p. 35-47, jan./mar. 2010. Disponível em: <<http://www.scielo.br/pdf/sausoc/v19n1/04.pdf>>. Acesso em: 01 ago. 2021.
9. LAI, Y.-R.; CHIU, W.-C.; HUANG, C.-C.; CHENG, B.-C.; KUNG, C.-T.; LIN, T. Y.; CHIANG, H. C.; TSAI, C.-J.; KUNG, C.-F.; LU, C.-H. Longitudinal artificial intelligence-based deep learning models for diagnosis and prediction of the future occurrence of polyneuropathy in diabetes and prediabetes. *Neurophysiologie Clinique*, v. 54, p. 102982, 2024. Disponível em: <https://doi.org/10.1016/j.neucli.2024.102982>. Acesso em: 15 nov. 2024.
10. LIU, S.; GAO, Y.; SHEN, Y.; ZHANG, M.; LI, J.; SUN, P. Application of three statistical models for predicting the risk of diabetes. *BMC Endocrine Disorders*, v. 19, n. 126, p. 1-10, 2019. Disponível em: <https://doi.org/10.1186/s12902-019-0456-2>. Acesso em: 15 nov. 2024.
11. LAVIKAINEN, P.; CHANDRA, G.; SIIRTOLA, P.; TAMMINEN, S.; IHALA-PATHIRANA, A. T.; RÖNING, J.; LAATIKAINEN, T.; MARTIKAINEN, J. Data-driven identification of long-term glycemia clusters and their individualized predictors in Finnish patients with type 2 diabetes. *Clinical Epidemiology*, v. 15, p. 13- 29, 2023. Disponível em: <https://doi.org/10.2147/CLEP.S380828>. Acesso em: 16 nov. 2024.
12. SRINIVASU, P. N.; SHAFI, J.; KRISHNA, T. B.; SUJATHA, C. N.; PRAVEEN, S.P.; IJAZ, M. F. Using recurrent neural networks for predicting type-2 diabetes from genomic and tabular data. *Diagnostics*, v. 12, n. 12, p. 3067, 2022. Disponível em: <https://doi.org/10.3390/diagnostics12123067>. Acesso em: 16 nov. 2024.
13. YUN, Chuan; TAN, Fangli; GAO, Zhenxiu; WANG, Wenjun; BAI, Fang; MILLER, Joshua D.; LIU, Huanhuan; LEE, Yaujiunn; LOU, Qingqing. Construction of risk prediction model of type 2 diabetic kidney disease based on deep learning. *Diabetes & Metabolism Journal*, v. 48, p. 771-779, 2024. Disponível em: <https://doi.org/10.4093/dmj.2023.0033>. Acesso em: 16 nov. 2024.
14. AKHTER FARUQUI, Syed Hasib et al. Development of a Deep Learning Model for Dynamic Forecasting of Blood Glucose Level for Type 2 Diabetes Mellitus. *JMIR*

mHealth and uHealth, v. 7, n. 11, p. e14452, 2019. Disponível em: <https://mhealth.jmir.org/2019/11/e14452/>. Acesso em: 17 nov. 2024.

15. LJUBIC, Branimir et al. Predicting Complications of Diabetes Mellitus Using Advanced Machine Learning Algorithms. Open Cardiovascular and Renal Medicine Journal, v. 13, n. 4, p. 2020. Disponível em: <https://academic.oup.com/ocaa120>. Acesso em: 17 nov. 2024