

## Previsão Não Invasiva de Risco de Pé Diabético com *Confident Learning*

Lucas Alexandre Alvarenga Cardoso \*  
Giovanna Gouvêa Spuri de Miranda \*\* Danilo Piveta Alvarenga \*\*\*  
Arthur Phillipe Marcondes Souza \*\*\*\*  
Ana Cláudia Barbosa Honório Ferreira †  
Maria Helena Baena de Moraes Lopes ‡ Danton Diego Ferreira §

\* Departamento de Automática, Universidade Federal de Lavras, MG,  
(e-mail: lucas.cardoso@estudante.ufla.br).

\*\* Departamento de Automática, Universidade Federal de Lavras, MG,  
(giovanna.miranda1@estudante.ufla.br)

\*\*\* Departamento de Automática, Universidade Federal de Lavras, MG,  
(danilo.alvarenga@estudante.ufla.br)

\*\*\*\* Departamento de Automática, Universidade Federal de Lavras,  
MG, (e-mail: arthur.souza@estudante.ufla.br)

† Centro Universitário de Lavras, MG, (e-mail:  
ananep@yahoo.com.br).

‡ Escola de Enfermagem, Universidade Estadual de Campinas, SP,  
(e-mail: mhbaena@unicamp.br).

§ Departamento de Automática, Universidade Federal de Lavras, MG,  
(e-mail: danton@ufla.br).

---

**Abstract:** Diabetic foot is a condition caused by diabetes mellitus (DM) that can cause irreversible damage, such as amputation and other complications. This article aims to classify patients diagnosed with DM in high or low risk of developing diabetic foot using the Confident Learning (CL) method. CL enables the removal of noisy data and, consequently, provides a more reliable classification. The available database is composed of 54 known risk factors of 250 patients diagnosed with DM. The development of the method was divided into: (i) feature selection; and (ii) application of the CL technique. The results showed that there is a gain of 6% in sensitivity, 14% in specificity and 9% in accuracy when removing noise from the diabetic foot ulcer risk classifier database. In addition, when comparing the competitive neural layer-based method with the proposed one, the CL-based method presented a sensitivity 26% and an accuracy 4% higher than the competitive neural layer-based method, but it has a specificity 13% lower.

**Resumo:** O pé diabético é uma condição causada pela diabetes *mellitus* (DM) e que pode causar danos irreversíveis, como amputação e outras complicações. Este artigo tem por objetivo classificar pacientes diagnosticados com DM em alto ou baixo risco de desenvolver pé diabético utilizando o método *Confident Learning* (CL). O CL possibilita a remoção dos dados ruidosos e, por consequência, fornece uma classificação mais confiável. A base de dados disponível possui 54 fatores de risco conhecidos de 250 pacientes diagnosticados com DM. O desenvolvimento do método proposto foi dividido em: (i) seleção de características e (ii) aplicação da técnica *Confident Learning*. Os resultados mostraram que há um ganho de 6% na sensibilidade, 14% na especificidade e 9% na acurácia ao remover o ruído do banco de dados do classificador de risco de desenvolvimento da úlcera do pé diabético. E ao comparar o método proposto com o método baseado em *Competitive neural layer* tem-se que o método proposto possui uma sensibilidade 26% e acurácia 4% superior ao *Competitive neural layer*, porém apresenta especificidade 13% menor.

**Keywords:** confident learning; diabetes mellitus; artificial intelligence; machine learning algorithm.

**Palavras-chaves:** *confident learning*; diabetes *mellitus*; inteligência artificial; algoritmo de aprendizagem de máquina.

---

## 1. INTRODUÇÃO

A diabetes *mellitus* (DM) é classificada como uma síndrome metabólica de origem múltipla, decorrente da falta de insulina e/ou da incapacidade de a insulina exercer adequadamente seus efeitos (MinistériodaSaúde, 2021).

Segundo a Organização Mundial de Saúde (OMS, 2021), cerca de 422 milhões de pessoas no mundo possuem diabetes *mellitus* e 1,6 milhões de mortes ao ano são atribuídas a essa doença. Ferreira (2020b) estima que em 2040 haverá 642 milhões de pessoas com diabetes no mundo, o que equivale a 10% da população do Planeta.

Entre as mais temidas complicações associadas à diabetes *mellitus* está o desenvolvimento da úlcera do pé diabético, termo empregado para nomear as diversas alterações e complicações ocorridas, isoladamente ou em conjunto, nos pés e nos membros inferiores das pessoas com diabetes (Caiafa et al., 2011).

Existem várias complicações da DM, mas este artigo tem como foco a avaliação de risco para o chamado “pé diabético”, que é uma das complicações mais graves e que possui alto custo de tratamento e resulta em um alto índice de morbidade (Bakker et al., 2012).

O pé diabético leva a longos períodos de hospitalização, alto custo de tratamento e à possibilidade de amputação do membro, conforme OMS (2021). O cuidado adequado dos pés, o bom controle da glicemia e a educação podem prevenir até 85% das amputações de membros inferiores em pacientes com DM (Raspovic and Wukich, 2014; Chellan et al., 2012). Todavia, a forma mais eficaz de prevenir o pé diabético é a identificação precoce dos pacientes com alto risco de desenvolver essa complicação, o que indica a necessidade de mais estudos e o uso de tecnologias inovadoras que colaborem para o enfrentamento dessa doença.

Com o objetivo de atingir predições com um nível de exatidão maior, a mineração de dados vem orientando profissionais de saúde na tomada de decisões (Kaur and Wasan, 2006; Kitsantas, 2009). A inteligência artificial (IA), com base nas informações de autocuidado fornecidas pela OMS, auxilia na classificação do risco do portador de diabetes *mellitus* desenvolver úlcera.

Dentre as ferramentas de IA, o campo de algoritmos supervisionados é geralmente mais explorado para auxiliar no diagnóstico. Entretanto, os algoritmos supervisionados requerem um banco de dados rotulado, ou seja, um banco de dados em que cada amostra esteja devidamente enquadrada em sua classe. Além disso, é necessário a obtenção de dados das mais distintas etnias, gêneros e faixa etárias, para assim, conseguir montar um banco de dados amplo e inclusivo o suficiente para que, tanto o algoritmo quanto o profissional da saúde que irá analisar os dados tenham o suporte necessário para evitar erros ou negligências causados pela falta de diversificação de dados coletados (Ghassemi and Nsoesie (2022)).

Na área da saúde, se tratando de previsão de risco de enfermidades, para a obtenção do rótulo de cada amostra é necessário que o profissional da saúde faça uma análise das características do paciente e indique o risco de desenvolver determinada enfermidade. Com isso, a rotulação dos dados

é, portanto, passível de erros. Do ponto de vista de IA, os erros nos rótulos podem prejudicar bastante a acurácia final do classificador/preditor. Desta maneira, é preciso atentar para que algoritmos de IA não tenham seu funcionamento prejudicado ao ser alimentado com dados ruidosos (Resende et al., 2020).

O *Confident Learning* (CL) é uma ferramenta capaz de encontrar amostras com rótulos ruidosos, podendo assim tornar possível a retirada dessa informação do conjunto de dados e tornar o modelo de classificação mais confiável (Northcutt et al., 2021).

Com o objetivo de identificar automaticamente pacientes com DM com alto risco de desenvolver pé diabético, Ferreira et al. (2020) construíram um banco de dados contendo 54 fatores de risco conhecidos de 250 pacientes diagnosticados com diabetes *mellitus* e utilizaram o método baseado em camada de neurônios competitivos (*competitive neural layer* - CNL) para agrupar os dados. Os pacientes selecionados foram agrupados pela CNL em dois grupos: Grupo A com 127 pacientes diabéticos e Grupo B com 112 pacientes diabéticos. Ferreira et al. (2020) constataram que o Grupo B era composto por pacientes com maior risco de desenvolver pé diabético e seu método atingiu 71% de sensibilidade, 100% de especificidade e 90% de acurácia.

Este estudo propõe um método não invasivo de classificação de risco de desenvolvimento de pé diabético baseado na técnica *Confident Learning* (CL) com o objetivo de melhorar os resultados obtidos por Ferreira et al. (2020).

O restante deste artigo está organizado da seguinte forma. A próxima seção apresenta uma revisão de literatura sobre o *confident learning*. Em seguida, tem-se uma descrição da base de dados e da metodologia aplicada para realizar a classificação utilizando o *confident learning*. Por fim, são apresentados os resultados e as conclusões.

## 2. CONFIDENT LEARNING

O *Confident Learning* (CL) é uma abordagem alternativa que, em vez de pautar no modelo de previsões, concentra-se na qualidade do rótulo, caracterizando-o e identificando os erros em conjuntos de dados, com base nos princípios de eliminação de dados ruidosos, contando com limites probabilísticos para estimativa de ruído e exemplos de classificação para treinar com confiança (Northcutt et al., 2021).

Northcutt et al. (2021) afirmam que o CL surgiu para tratar a incerteza nos rótulos dos conjuntos de dados, da qual dois aspectos se destacaram: o processo de classificação do ruído (CNP) e a estimativa direta da distribuição conjunta de dados e rótulos desconhecidos.

O processo de classificação do ruído fornece uma suposição inicial de que o rótulo do ruído é condicional à classe, dependendo apenas da verdadeira classe latente, não do vetor de atributos (ou características). Com isso, enquanto houver exceções, essa suposição é comumente usada porque é razoável para muitos conjuntos de dados (Goldberger and Ben-Reuven, 2016).

A estimativa direta da distribuição conjunta entre rótulos ruidosos (dados) e rótulos verdadeiros (desconhecidos)

pode ser buscada de forma eficaz, conforme Northcutt et al. (2021), com base em três abordagens principiológicas usadas em muitos estudos relacionados:

- Prune: para procurar erros de rótulo, por exemplo eliminando por meio de reponderação com perda, para evitar armadilhas de convergência de rotulagem iterativa;
- Contagem: para treinar em dados limpos, evitando propagação de erro em pesos de modelo aprendidos e reponderar a perda com probabilidades preditas imperfeitas;
- Classificação: para listar quais exemplos utilizar durante o treinamento, para permitir o aprendizado com probabilidades não-normalizadas ou distâncias limites de decisão, com base em descobertas de robustez e ideias de aprendizado de currículo.

Kertész (2021) explica, de modo simplificado, o método de Northcutt et al. (2021) como “se uma amostra  $s$  for identificada com o rótulo incorreto, um novo rótulo  $l'$  é sugerido no lugar do rótulo original  $l$ ”. Sendo assim, o *confident learning* pode ser definido pela Eq. (1).

$$N'_m = CL(S, L, m, P, f_n), \quad (1)$$

$$f_n \in [0, 1], \quad (s'_i, l'_i) \in N'_m, \quad i \in \{0, \dots, k-1\}$$

em que  $CL$  possui um conjunto de amostras ( $S$ ), com rótulos anotados ( $L$ ) e previsões ( $P$ ) do modelo  $m$  para produzir  $k$  amostras ruidosas com rótulos candidatos ( $|N'_m| = k$ ). A fração de ruído ( $f_n$ ) é um hiperparâmetro entre  $[0, 1]$  para controlar o retorno fração de rótulos ruidosos por classe. Os hiperparâmetros fixos do *confident learning* são definidos pela taxa de ruído e ordenando os índices de rótulo por uma margem normalizada (Kertész, 2021).

Kertész (2021) afirma que para um conjunto de modelos ( $M$ ), os candidatos a rótulos são reunidos para cada amostra conforme a Eq. (2).

$$(s_i, L_i) \in N'_S, \quad \forall s \in S, \quad \exists (s, l') \in N'_m$$

$$L'_i = (l'_0, l'_1, \dots, l'_p), \quad (2)$$

$$0 \leq p < |M|$$

em que  $N'_S$  contém as listas de rótulos candidatos para cada amostra e o mesmo rótulo pode ocorrer várias vezes em  $L'_i$ . Quanto mais vezes uma amostra for considerada mal rotulada pelo *confident learning* com o mesmo rótulo de candidato, mais provável é que o rótulo verdadeiro seja esse candidato. A anotação ( $l_i \in L$ ) é fixa para uma amostra  $s_i$  quando as seguintes condições forem atendidas:

$$|L'_i| \geq h_1$$

$$|L'_i| \leq 3$$

em que  $h_1$  é o número de modelos que consideram a amostra rotulada incorretamente e há menos de três candidatos

únicos. A amostra  $s_i$  e o candidato mais frequente de  $L'_i$  são adicionados a  $S_f$  neste caso. Uma amostra  $s_i$  é adicionada a  $S_r$  para remoção se os itens exclusivos em  $L'_i$  estão acima de um certo limite  $h_2$  ( $|L'_i| \geq h_2$ ). Amostras marcadas para correções de anotação não podem ser removidas de  $S((s_i, l'_i) \in S_f \Rightarrow s_i \notin S_r)$  (Kertész, 2021).

Para aplicar o *confident learning*, os modelos  $M$  e  $f_n$ ,  $h_1$ ,  $h_2$  devem ser definidos. Esses últimos hiperparâmetros podem ser encontrados empiricamente após uma experimentação inicial com um conjunto de dados. Segundo Northcutt et al. (2017), para que o *confident learning* tenha um bom desempenho é necessário um conjunto de dados bem representado e completo juntamente com uma construção de modelo bem otimizada.

### 3. METODOLOGIA

O desenvolvimento do trabalho foi dividido em: (i) extração de características e (ii) aplicação da técnica *Confident Learning*.

#### 3.1 Base de Dados

A base de dados utilizada neste trabalho foi obtida de Ferreira et al. (2020), que selecionou aleatoriamente 250 pacientes de um centro de saúde localizado no estado de Minas Gerais, Brasil, para participarem da pesquisa através da aplicação de um questionário. O questionário utilizado foi adaptado de acordo com os parâmetros científicos de fatores de risco para o desenvolvimento do pé diabético proposto pelo Consenso Internacional sobre o Pé Diabético de 2001 (Newrick, 2000) e pelo folheto DM do Ministério da Saúde de 2006 (da Saúde, BR).

O questionário foi baseado nos hábitos de autocuidado dos pacientes em relação à sua saúde e cuidados com os pés, mas também incluiu informações sociodemográficas e socioeconômicas do paciente. Em detalhes, o questionário levantou informações da renda do sujeito, profissão, sexo, idade, anos de estudo, estado civil, índice de massa corporal (IMC), hábito de fumar, uso de álcool, tipo de diabetes, presença de hipertensão, problemas circulatórios, sensação de queimação nos pés, presença de joanete, exame do pé, ruga entre os dedos, hábito de lavar os pés, calosidades nos pés, tipo de calçado (estilo, material e construção), tempo entre a compra do calçado, hábitos de caminhada (descalço ou não), valor da glicose no sangue, se monitora a glicemia ou não, se faz controle alimentar, se tem ou já teve micose nos pés, dor nas pernas e pés, rachaduras atuais ou anteriores nos pés, bolha atual ou anterior nos pés, choque nos pés, calor e pés avermelhados, remoção de cutículas dos dedos dos pés, tipo de corte das unhas no pé, tipo de meia, ação realizada quando ocorreu o pé diabético, se verifica dentro do sapato, a posição de assistir televisão/leitura, tempo de em pé ou caminhando, tipo de tratamento, tempo com diabetes, prática de atividade física, formigamento nos pés, perda de sensibilidade nos pés, dormência nos pés, sentar nos pés, edema nos pés, alteração na estrutura do pé, hidratação dos pés, problemas de visão, unhas encravadas atuais ou anteriores, uso de bolsa quente nos pés, lesões atuais ou anteriores nos pés e presença de amputação de perna/pé. No total, cada paciente do banco de dados possui 54 variáveis.

Os dados de cada participante foram analisados, de forma independente, por dois especialistas em pé diabético que classificaram cada pessoa como de baixo ou alto risco para o pé diabético. Um terceiro especialista analisou os casos discordantes para obter o consenso final. Com base em suas experiências profissionais e na literatura, os especialistas indicaram o risco (alto risco ou baixo risco) que cada um dos participantes apresentava para o desenvolvimento do pé diabético (Ferreira, 2020a). Os dados dessa pesquisa estão disponíveis no endereço eletrônico <https://data.mendeley.com/datasets/hd7wtgs7dz/1> (Ferreira et al., 2022).

### 3.2 Seleção de Variáveis

Para a seleção de variáveis foram utilizados cinco algoritmos: Correlação de *Pearson* (Benesty et al., 2009), *Chi-Squared* (Greenwood and Nikulin, 1996), *Recursive Feature Elimination* (RFE) (Chen and Jeong, 2007), *Least Absolute Shrinkage and Selection Operator* (LASSO) (Kukreja et al., 2006) junto a um *Logistic Regression* (Wright, 1995; DeMaris, 1995; LaValley, 2008), *Random Forest* (Breiman, 2001; Chen and Ishwaran, 2012) e por último o Algoritmo Genético (GA) com uma *multilayer perceptron* (MLP) como classificador (Zhu and Wang, 2010; Talatian Azad et al., 2021). Para algumas dessas ferramentas, foi selecionada a quantidade de recursos desejados, já para o *Random Forest*, a própria ferramenta seleciona os recursos mais importantes.

A seleção de características final utilizada foi realizada ao combinar todos os extratores e assim selecionadas as características que foram ditas importantes mais vezes dentre as cinco formas de selecioná-las. Com isso, foram escolhidas as 15 características mais importantes do banco de dados.

### 3.3 Aplicação do *Confident Learning*

Após a seleção de características, foi aplicado o algoritmo *confident learning* (CL), o qual tem como objetivo encontrar amostras com ruído de classe (rótulos errados) e removê-las do banco de dados. O CL estima a distribuição conjunta de dados ruidosos e verdadeiros e, para isso, ele precisa apenas das probabilidades previstas para cada amostra.

Ao executar um perceptron multicamadas (MLP - *multilayer perceptron*) com todos os dados e usar o *k-fold*, com  $k = 10$ , todas as amostras têm a probabilidade prevista de pertencer às classes em questão. Com isso, alimenta-se o algoritmo de *confident learning* com essas probabilidades e ele tem como meta o cálculo de um limite que diz com confiança se a amostra tem o rótulo correto ou ruidoso. A MLP utilizada para estimar as probabilidades foi composta por 15 nodos de entrada (variáveis de entrada), uma camada intermediária com 10 neurônios, função de ativação tangente hiperbólica, e 2 neurônios de saída com função de ativação *softmax*. Esta última foi escolhida para estimar as probabilidades, que serão parâmetros de entrada para o algoritmo CL.

Com esse limite em mãos, a distribuição conjunta de rótulos ruidosos e corretos é encontrada. Após o corte de amostras com rótulos considerados ruidosos, a classificação

com dados ditos corretos pode ser realizada. Para isso, uma MLP foi utilizada tanto para os dados livres de ruído quanto para o banco de dados inteiro, a fim de comparar os resultados. A MLP foi composta por 15 nodos de entrada (variáveis de entrada), uma camada intermediária com 10 neurônios, função de ativação tangente hiperbólica, e 1 neurônio de saída com função de ativação *sigmoid*. O algoritmo de treinamento foi o método do gradiente descendente estocástico ('*Adam*') (Kingma and Ba, 2014), que é baseado na estimativa adaptativa de momentos de primeira e segunda.

Obtido este limite, a distribuição conjunta de rótulos ruidosos e corretos é encontrada. Após o corte de amostras com rótulos considerados ruidosos, a classificação com dados corretos pode ser realizada. Para isso, foi utilizada uma *multilayer perceptron* (MLP) tanto para os dados livres de ruído quanto para o banco de dados inteiro, a fim de comparação de resultados.

## 4. RESULTADOS

Os fatores que apresentaram um resultado significativo da análise estatística foram: tipo de corte das unhas; tem/teve ferida nos pés; sente formigamento em pernas e pé; sente choque em pernas e pés; percebe diferença nos ossos dos pés; já sentiu perda de sensibilidade; coloca água quente nos pés; unhas dos pés encravam; tempo com diabetes; tem calos nos pés; tem bolha nos pés; sente dormência em pernas e pés; hábito de retirar cutículas; sente pontada em pernas e pés e material do calçado. Estas foram as *features* que foram indicadas como importantes por pelo menos quatro extratores, totalizando 15 características para implementação do CL e da MLP. As características selecionadas pelos extratores são apresentadas na Tabela 1.

Importante destacar que sete das quinze variáveis utilizadas pelo modelo proposto são variáveis modificáveis, ou seja, com apoio da equipe de saúde e autocuidado é possível modificá-las num sentido positivo, ou seja, elas podem passar a contribuir no modelo para que o paciente seja baixo risco. Estas variáveis são: 1-Tipo de corte das unhas; 7-Coloca água quente nos pés; 8-Unhas dos pés encravam; 10-Tem calos nos pés; 11-Tem bolha nos pés; 13-Hábito de retirar cutículas e 15-Material do calçado. Este resultado é interessante para que as equipes de saúde possam direcionar ações específicas e personalizadas para cada paciente de acordo com suas respostas a estas variáveis.

O CL encontrou ruído em 25 das 250 amostras do banco de dados. Essas amostras foram retiradas do banco de dados e a classificação final com uma MLP foi realizada. Para fins de comparação, também foi realizada a classificação com o banco de dados sem o corte das amostras ruidosas. Ao usar um *k-fold* com 10 *folds*, as métricas apresentadas foram a média de todos os *folds* para Sensibilidade, Especificidade, Acurácia, VPP e VPN. Os resultados são apresentados na Tabela 2.

A estrutura de MLP empregada alcançou uma média de 91% de sensibilidade com ruído e 97% sem ruído, 73% de especificidade com ruído e 87% sem ruído e obteve-se ainda uma acurácia média de 85% para os dados com ruído e 94%

Tabela 1. Características selecionas pelos extratores.

Feature	Pearson	Chi-2	RFE	Logistics	Random Forest	GA	Total
1 Tipo de corte das unhas	True	True	True	True	True	True	6
2 Tem/teve ferida nos pés	True	True	True	True	True	True	6
3 Sente formigamento em pernas e pés	True	True	True	True	True	True	6
4 Sente choque em pernas e pés	True	True	True	True	True	True	6
5 Percebe diferença nos ossos dos pés	True	True	True	True	True	True	6
6 Já sentiu perda de sensibilidade	True	True	True	True	True	True	6
7 Coloca água quente nos pés	True	True	True	True	True	True	6
8 Unhas dos pés encravam	True	True	True	True	True	True	6
9 Tempo com diabetes	True	False	True	True	True	True	5
10 Tem calos nos pés	True	True	True	True	True	False	5
11 Tem bolha nos pés	True	True	True	True	False	True	5
12 Sente dormência em pernas e pés	True	True	True	True	True	False	5
13 Hábito de retirar cutículas	True	True	True	True	False	True	5
14 Sente pontada em pernas e pés	True	True	False	False	True	True	4
15 Material do calçado	False	False	True	True	True	True	4

sem ruído. Observa-se, portanto, que os ganhos com o uso de CL para remoção de amostras com erros em rótulos (ruídos) são consideráveis.

Tabela 2. Desempenho do método proposto.

	Com Ruído		Sem Ruído (com CL)	
	Média	Desvio Padrão	Média	Desvio Padrão
<b>Sensibilidade</b>	0,91	0,06	0,97	0,05
<b>Especificidade</b>	0,73	0,17	0,87	0,12
<b>Acurácia</b>	0,85	0,05	0,94	0,06
<b>VPP</b>	0,87	0,09	0,93	0,07
<b>VPN</b>	0,82	0,15	0,95	0,09

Uma análise mais aprofundada pode ser realizada na saída do modelo. Ao usar a função de ativação *sigmoide*, a saída passa a ser um valor entre 0 e 1 para cada amostra e, ao definir um limite de 0,5, pode-se separar amostras positivas para alto risco quando a saída for maior do que esse limite e baixo risco para saídas menores do que esse limite. A Fig. 1 ilustra a saída da sigmoide para cada um dos 10 *folds*, mostrando as amostras que são classificadas de forma errada e seus respectivos valores. Um dado de baixo risco receber um valor próximo a 1 é um forte indicativo de que essa amostra tem um ruído de classe, visto que foi classificada com muita certeza, mas na classe errada, o que acontece claramente para os *folds* 1, 2, 6, 7, 8 e 9.

A Fig. 2 mostra as amostras selecionadas pelo CL como amostras com erros de rótulo (ruído) em cada um dos *folds*. A remoção dessas amostras da base de dados e um novo projeto de classificador via MLP leva a melhorias consideráveis nos resultados, o que pôde ser visto na Tabela 2. No entanto, é importante aplicar este classificador final a uma nova base de dados para se ter uma ideia da generalização do método e avaliar possíveis erros em rótulos para verificar como o modelo lida com novas amostras

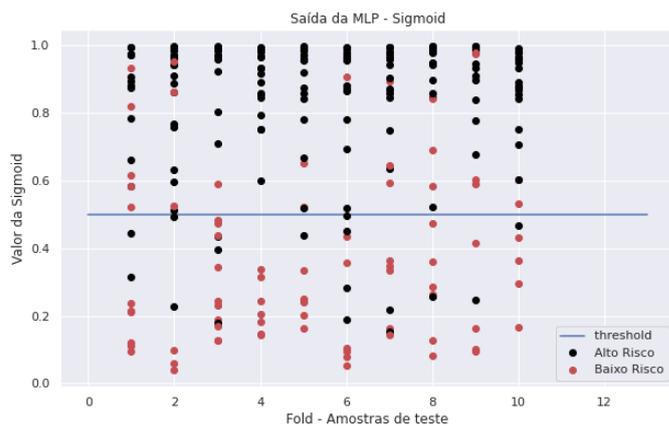


Figura 1. Saída da *sigmoid* da MLP proposta para cada *fold*.

com rótulos ruidosos. Espera-se realizar esta análise em trabalhos futuros.

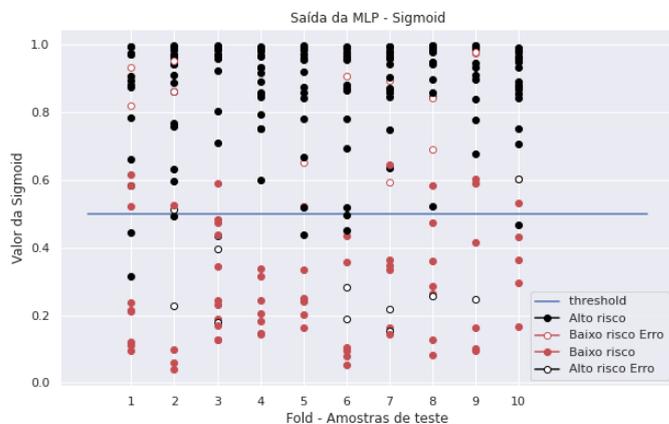


Figura 2. Amostras selecionadas pelo *Confident Learning* como amostras com erro de rótulo.

O trabalho reportado em Ferreira et al. propõe uma camada neural competitiva (*Competitive neural layer-CNL*) para classificação de risco de desenvolvimento de pé diabético, em que a mesma base de dados foi empregada. Ao comparar os resultados encontrados em Ferreira et al. com os obtidos neste trabalho, tem-se que o *confident learning* apresenta uma sensibilidade 26% e acurácia 4% superior ao CNL, porém apresenta especificidade 13% menor. Estes resultados reforçam a importância de se empregar métodos para lidar com rótulos ruidosos.

## 5. CONCLUSÕES

Este trabalho empregou uma técnica para lidar com amostras com rótulos ruidosos no treinamento de um classificador para identificação de risco de desenvolvimento de pé diabético. Dentre os resultados encontrados neste estudo, pode-se concluir que há um ganho de 6% na sensibilidade, 14% na especificidade e 9% na acurácia ao remover o ruído do banco de dados do classificador de risco de desenvolvimento da úlcera do pé diabético.

Uma análise de seleção de variáveis envolvendo sete métodos diferentes foi realizada, no intuito de desvendar aquelas variáveis que mais contribuem para distinguir o paciente entre os grupos de alto e baixo risco de desenvolver o pé diabético. Foram identificadas quinze variáveis mais discriminantes e, dentre elas, sete são variáveis modificáveis e, portanto, podem ser trabalhadas com ações de autocuidado pelo paciente e pela equipe de saúde local.

Em trabalhos futuros espera-se validar o modelo proposto em uma nova base de dados que está sendo levantada pela equipe envolvida.

## AGRADECIMENTOS

Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e a Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) por apoiarem este trabalho.

## REFERÊNCIAS

- Bakker, K., Apelqvist, J., Schaper, N.C., and on the Diabetic Foot Editorial Board, I.W.G. (2012). Practical guidelines on the management and prevention of the diabetic foot 2011. *Diabetes/metabolism research and reviews*, 28, 225–231.
- Benesty, J., Chen, J., Huang, Y., and Cohen, I. (2009). Pearson correlation coefficient. In *Noise reduction in speech processing*, 1–4. Springer.
- Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5–32.
- Caiafa, J.S., Castro, A.A., Fidelis, C., Santos, V.P., Silva, E.S.d., and Sitrângulo Jr, C.J. (2011). Atenção integral ao portador de pé diabético. *Jornal vascular brasileiro*, 10(4), 1–32.
- Chellan, G., Srikumar, S., Varma, A.K., Mangalanandan, T., Sundaram, K., Jayakumar, R., Bal, A., and Kumar, H. (2012). Foot care practice—the key to prevent diabetic foot ulcers in india. *The Foot*, 22(4), 298–302.
- Chen, X. and Ishwaran, H. (2012). Random forests for genomic data analysis. *Genomics*, 99(6), 323–329.
- Chen, X.w. and Jeong, J.C. (2007). Enhanced recursive feature elimination. In *Sixth International Conference on Machine Learning and Applications (ICMLA 2007)*, 429–435. IEEE.
- da Saúde (BR), M. (2006). Caderno de atenção básica-diabetes mellitus.
- DeMaris, A. (1995). A tutorial in logistic regression. *Journal of Marriage and the Family*, 956–968.
- Ferreira, A.C.B.H., Ferreira, D.D., Oliveira, H.C., de Resende, I.C., Anjos, A., and de Moraes Lopes, M.H.B. (2020). Competitive neural layer-based method to identify people with high risk for diabetic foot. *Computers in biology and medicine*, 120, 103744.
- Ferreira, A.C.B.H. (2020a). *Construção de um Classificador de Risco para Prevenção do Pé Diabético usando Redes Neurais Artificiais*. Ph.D. thesis, Universidade Estadual de Campinas, Campinas, SP, Brasil.
- Ferreira, D.D., Oliveira, I.R., Ferreira, A.C.B.H., de Moraes Lopes, M.H.B., and Anjos, A. (2022). Data for: Competitive neural layer-based method to identify people with high risk for diabetic foot. doi:10.17632/hd7wtgs7dz.1.
- Ferreira, R.C. (2020b). Diabetic foot. part 2: Charcot neuroarthropathy. *Revista Brasileira de Ortopedia*, 55, 397–403.
- Ghassemi, M. and Nsoesie, E.O. (2022). In medicine, how do we machine learn anything real? *Patterns*, 3(1), 100392.
- Goldberger, J. and Ben-Reuven, E. (2016). Training deep neural-networks using a noise adaptation layer.
- Greenwood, P.E. and Nikulin, M.S. (1996). *A guide to chi-squared testing*, volume 280. John Wiley & Sons.
- Kaur, H. and Wasan, S.K. (2006). Empirical study on applications of data mining techniques in healthcare. *Journal of Computer science*, 2(2), 194–200.
- Kertész, C. (2021). Automated cleanup of the imagenet dataset by model consensus, explainability and confident learning. *arXiv preprint arXiv:2103.16324*.
- Kingma, D.P. and Ba, J. (2014). Adam: A method for stochastic optimization.
- Kitsantas, P. (2009). Profiling overweight/obesity among preschoolers: A data mining approach. *Annals of Epidemiology*, 9(19), 661–662.
- Kukreja, S.L., Löfberg, J., and Brenner, M.J. (2006). A least absolute shrinkage and selection operator (lasso) for nonlinear system identification. *IFAC proceedings volumes*, 39(1), 814–819.
- LaValley, M.P. (2008). Logistic regression. *Circulation*, 117(18), 2395–2399.
- MinistériodaSaúde (2021). Diabetes. <https://bvsmms.saude.gov.br/diabetes/>. Último acesso em 22 de abril de 2022.
- Newrick, P. (2000). International consensus on the diabetic foot.
- Northcutt, C., Jiang, L., and Chuang, I. (2021). Confident learning: Estimating uncertainty in dataset labels. *Journal of Artificial Intelligence Research*, 70, 1373–1411.
- Northcutt, C.G., Wu, T., and Chuang, I.L. (2017). Learning with confident examples: Rank pruning for robust classification with noisy labels. *arXiv preprint arXiv:1705.01936*.
- OMS (2021). Diabetes. url<https://www.who.int/health-topics/diabetes>. Último acesso em 15 de abril de 2022.

- Raspovic, K.M. and Wukich, D.K. (2014). Self-reported quality of life and diabetic foot infections. *The Journal of Foot and Ankle Surgery*, 53(6), 716–719.
- Resende, I.C., Cardoso, L.A., Ferreira, A.C.B., Barbosa, B.H., and Ferreira, D.D. (2020). Identificação de grau de risco de pé diabético por meio de técnicas de aprendizado de máquinas. In *Congresso Brasileiro de Automática-CBA*, volume 2.
- Talatian Azad, S., Ahmadi, G., and Rezaeipanah, A. (2021). An intelligent ensemble classification method based on multi-layer perceptron neural network and evolutionary algorithms for breast cancer diagnosis. *Journal of Experimental & Theoretical Artificial Intelligence*, 1–21.
- Wright, R.E. (1995). Logistic regression.
- Zhu, M. and Wang, L. (2010). Intelligent trading using support vector regression and multilayer perceptrons optimized with genetic algorithms. In *The 2010 International Joint Conference on Neural Networks (IJCNN)*, 1–5. IEEE.