

# Identificação de Grau de Risco de Pé Diabético por meio de Técnicas de Aprendizado de Máquinas

Igor C. Resende\* Lucas A. A. Cardoso\*\*  
 Ana Cláudia B. H. Ferreira\*\*\* Bruno H. G. Barbosa\*\*\*\*  
 Danton D. Ferreira†

\* *Universidade Federal de Lavras, Departamento de Automática  
 (e-mail: igoresende@gmail.com).*

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

\*\*\* *Universidade Estadual de Campinas, Faculdade de Enfermagem,  
 Centro Universitário de Lavras (e-mail: ananepe@yahoo.com.br)*

\*\*\*\* *Universidade Federal de Lavras, Departamento de Automática  
 (e-mail: brunohb@ufla.br)*

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

---

**Abstract:** Foot complications (diabetic foot) are among the most serious and costly complications of Diabetes Mellitus. Amputation of all or part of a lower extremity is usually preceded by a foot ulcer. In order to prevent diabetic foot, this paper proposes an automatic system based on the K-means, decision trees and Genetic Algorithms to identify patients with diabetes who have a high risk of developing diabetic foot. To design the method, information concerning social scope and self-care of patients was taking into account. Both real and simulated data were used to evaluate the method. Accuracy higher than 90% was achieved showing that the method can be useful at Basic Health Units to triage of diabetic patients helping the healthcare team to reduce the number of cases of diabetic foot.

**Resumo:** O pé diabético está entre as mais sérias e dispendiosas complicações causadas pela Diabetes Mellitus. A amputação de extremidades inferiores geralmente é consequência de uma úlcera nos pés. Para prevenir o pé diabético, este trabalho propõe um sistema automático baseado em K-means, árvores de decisão e algoritmos genéticos para identificar os pacientes com alto risco de desenvolver o pé diabético. No projeto do método, informações sobre a situação social e autocuidados dos pacientes com os pés são consideradas. Ambos dados reais e simulados foram usados para avaliar o método proposto. Um desempenho superior a 90% foi obtido, mostrando que o método pode ser útil em Unidades Básicas de Saúde na triagem de pacientes diabéticos em apoio às equipes de saúde, com consequências na redução do número de casos de pés diabéticos.

*Keywords:* Data clustering; Diabetic Foot; Diabetes Mellitus.

*Palavras-chaves:* Agrupamento de dados; Pé Diabético; Diabetes Mellitus.

---

## 1. INTRODUÇÃO

O setor de saúde tem sido destaque na busca de alternativas para ajudar o diagnóstico médico. Para lidar com essas alternativas, torna-se necessário o desenvolvimento de um processamento rápido e preciso de informações, ou seja, Mineração de Dados. A mineração de dados vem conquistando seu espaço em diagnósticos médicos, auxiliando na tomada de decisão dos profissionais de saúde (Kaur and Wasan, 2006) (Kitsantas, 2009).

Na área de Diabetes Mellitus, destacam-se os trabalhos (Lee et al., 2010) (Karegowda et al., 2012) (Antonelli et al., 2013) (Appuhamy et al., 2013) (Espeland et al., 2009). Lee et al. (2010) realizaram um estudo para desenvolver um sistema de monitoramento e gestão de assessoria

em pacientes diabéticos utilizando o método baseado em regras e o algoritmo k-vizinhos mais próximos (KNN). Karegowda et al. (2012) apresentou um modelo híbrido que classifica os dados de diabetes índios Pima usando o algoritmo k-means para identificar e eliminar os casos que não são classificados corretamente, algoritmos genéticos para selecionar as variáveis, e o KNN para a classificação final. Antonelli et al. (2013) apresentou uma análise de dados que identifica uma determinada doença por meio de testes realizados por pacientes diabéticos (história exame). Appuhamy et al. (2013) propuseram uma estrutura matemática para a previsão de prevalência de diabetes usando taxas de incidência estimadas dentro do modelo usando dados de índice de massa corporal. Espeland et al. (2009) exploraram análise de componentes principais para descrever padrões de alterações de peso em resposta a uma

intervenção de estilo de vida intenso em indivíduos com diabetes tipo 2.

Os estudos de sistemas e de reconhecimento de padrões anteriormente mencionados demonstraram o sucesso da aplicação de métodos inteligentes em parceria com profissionais de saúde, a fim de apoiá-los, auxiliando na tomada de decisão e classificação dos pacientes.

De acordo com a Organização Mundial de Saúde, Diabetes Mellitus é considerada a sétima causa de morte no mundo ao obter uma percentagem de 2,8% em 2016 (Organização, 2018). Diabetes Mellitus é um grupo de doenças metabólicas caracterizadas por hiperglicemia e associada a complicações e distúrbios de vários órgãos (Ekoé et al., 2008). Complicações do pé estão entre as complicações mais graves e onerosas que afetam os indivíduos com diabetes, o que representa um grande encargo de saúde com morbidade significativa (Bakker et al., 2012) (Game et al., 2012) (Karthikesalingam et al., 2010). Úlceras nos pés são representados por um estado multifacetado, assimilado pelo aparecimento de lesões que ocorrem devido à neuropatia. Essas úlceras são caracterizadas por lesões cutâneas com perda de epitélio, que se prolonga para dentro da derme, pode atingir profundamente nos tecidos, e, assim, atingir processo muscular em 85% das amputações (Ekoé et al., 2008) (Jeffcoate, 2005).

Além disso, as úlceras do pé podem causar sérios problemas no impacto da saúde física do paciente na qualidade de vida dos mesmos. Estudos têm demonstrado que os pacientes com diabetes e úlcera de pé tinham mais depressão e baixa qualidade de vida (Tennvall and Apelqvist, 2000) (Green et al., 2012). Esta condição pode ser evitada com algum cuidado. A detecção precoce de úlceras nos pés e o cuidado com os pés são fundamentais para diminuir o impacto da doença.

Neste contexto, surge a possibilidade de um sistema para ajudar no diagnóstico precoce de pé diabético e medir o nível de conhecimento que o paciente tem sobre a autocuidado com os pés. Torna-se importante o desenvolvimento de metodologias que podem atuar de forma mais precisa nessa direção, evitando assim o desenvolvimento do pé diabético.

O objetivo deste trabalho é desenvolver um método não-invasivo e automático para a identificação precoce de pacientes diabéticos com alto risco de desenvolver o pé diabético. O método proposto processa informações coletadas e fornece uma saída do quadro de pacientes diabéticos em dois grupos de risco de desenvolvimento do pé diabético: i) risco elevado e ii) de baixo risco. A decisão final do método é focada em informações do paciente sobre aspectos sociais, hábitos e autocuidado.

## 2. BASE DE DADOS

Realizou-se um levantamento de dados de pacientes diabéticos em uma cidade do interior de Minas Gerais, Brasil. Esses dados foram colhidos através de um formulário contendo 31 perguntas a respeito do âmbito social, hábitos e principalmente sobre os cuidados com os pés dos pacientes. A Tabela 1 mostra, resumidamente, as informações coletadas. O formulário de coleta foi previamente aprovado pelo Comitê de Ética (no. 51950). As informações foram

coletadas durante visitas domiciliares por um profissional devidamente treinado para tal e um representante do PSF (Posto de Saúde Familiar). Foi entrevistado um total de 153 pacientes portadores de diabetes. Dentre estes pacientes, 7 já foram diagnosticados como portadores do pé diabético. Esses dados foram usados no projeto e teste do método proposto.

Tabela 1. Informações Coletadas

Sexo	O que usa pra remover calor
Idade	Usa bolsa de água quente
Estado Civil	Retira cutículas dos pés
Ocupação (trabalha ou não trabalha)	Verifica o calçado por dentro antes de usar
Escolaridade	Tipo de calçado que usa
Tempo do diagnóstico de Diabetes	Atitude quando percebe alteração nos pés
Diabetes Tipo 1 ou 2	Aspecto interno do calçado
Tempo de tratamento do Diabetes	Hora do dia que sai pra comprar sapatos novos
Tipo de tratamento	Costuma andar descalço
Hábito de examinar os pés	Tipo de meia que usa (material)
Como corta as unhas dos pés	Tipo de meia que usa (aspecto e costura)
O que usa pra lavar os pés	Posição ao assistir televisão
Hábito de lavar os pés	Material do calçado que usa
O que usa pra enxugar os pés	Já percebeu alteração nos pés
Enxuga entre os dedos dos pés	Já foi diagnosticado com pé diabético
Usa creme hidratante nos pés	

Após a coleta dos dados via formulários, as informações foram analisadas por especialista da saúde a fim de identificar informações incoerentes, que quando encontradas foram corrigidas. As informações literais foram codificadas adotando valores pertencentes ao intervalo  $[-1, 1]$ .

Com o objetivo de validar o método proposto, foram simuladas informações relativas a 30 pacientes. Estas informações foram geradas de acordo com os especialistas da área de saúde. Na geração destas informações, buscou-se garantir que 15 pacientes apresentassem alto risco de desenvolver o pé diabético e 15 apresentassem baixo risco.

## 3. MÉTODO PROPOSTO

O projeto do método proposto pode ser dividido em etapas, conforme ilustra o diagrama em blocos da Figura 1(a). A primeira etapa é a coleta das informações e formação do banco de dados (codificação das informações) que é realizada conforme descrito na Seção 2.

A segunda etapa, de pré-processamento, é responsável por normalizar as variáveis de entrada referentes a idade dos pacientes, tempo (em anos) em que o paciente é diabético e tempo (em anos) em que o paciente trata a diabetes. Essa normalização foi realizada de acordo com (1).

$$\mathbf{z}_i = \frac{\mathbf{x}_i - \mu_i}{\max(\mathbf{x}_i) - \mu_i} \quad (1)$$

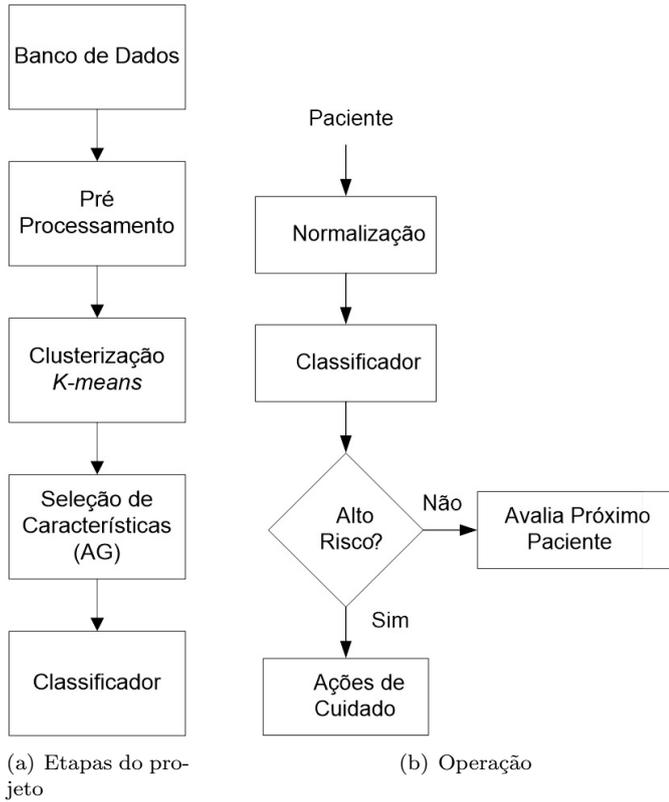


Figura 1. Método Proposto

em que  $x_i$  e  $\mu_i$  são, respectivamente, o vetor da variável  $i$  dos pacientes e a sua média  $z_i$  é o vetor de variáveis normalizado.

Ainda na etapa de pré-processamento, a correlação linear entre as 31 variáveis de entrada foi aplicada com o objetivo de identificar redundância entre as mesmas. Observou-se que a variável referente ao tempo em que o paciente foi diagnosticado como paciente diabético apresentou uma correlação de 0,95 com a variável referente ao tempo em que o paciente trata o problema de diabetes. Dessa forma, eliminou-se a variável referente ao tempo em que o paciente trata o problema de diabetes, e passou-se a trabalhar com 30 variáveis. As demais correlações foram inferiores a 0,40 e, portanto, as demais variáveis foram mantidas.

Após a etapa de pré-processamento os dados são agrupados em dois grupos (*clusters*). A clusterização é realizada pelo método *k-means* (Gagliardi, 2011), escolhido por ser prático e eficiente (Santos A., 2003). O método *k-means* visa à partição de  $N$  observações em  $k$  *clusters*. Cada observação é classificada em determinado *cluster*, através da menor distância euclidiana para um dos centroides. Os centroides estão posicionados no centro de aglomerados (Breiman et al., 1984).

A próxima etapa do projeto do método proposto consiste em avaliar os *clusters* obtidos. Para isso utilizou-se um indicador de qualidade entre homogeneidade *intra-cluster* e *inter-cluster*, conhecido por *silhouettes* (Linden, 2006). O *silhouettes* é um método de interpretação e validação de conjunto de dados através de um gráfico que representa como cada objeto encontra-se dentro de seu *cluster*. O valor de cada *silhouettes* é calculado conforme (2).

$$s(p_i) = \frac{b(p_i) - a(p_i)}{\max\{a(p_i), b(p_i)\}}, \quad (2)$$

$$s(p_i) \in [-1, 1],$$

em que  $p_i$  é um evento da classe  $i$ ,  $b(p_i)$  é a menor distância média de  $p_i$  a todos os pontos do grupo de dados em que  $p_i$  não pertence.  $a(p_i)$  é a distância média entre  $p_i$  e todos os outros dados dentro do mesmo grupo. Valores negativos representam silhueta colocações erradas de pacientes, enquanto que os valores positivos referem-se às atribuições melhores do paciente (Ferrero, 2009).

Após a avaliação dos *clusters*, o Algoritmo Árvore de Decisão (AD) (Aha et al., 1991) (Santos A., 2003) foi aplicado para gerar um classificador final baseado nas variáveis. O uso de árvores de decisão nesta etapa foi importante para levantar as variáveis (dentre as 30) mais relevantes na divisão entre os grupos de alto e baixo risco. Ressalta-se que as árvores de decisão tem a habilidade de realizar a seleção de características de forma automática durante a construção da árvore, e as variáveis irrelevantes são descartadas.

Objetivando melhorar a eficácia do algoritmo de classificação, foi utilizado um algoritmo de Seleção. O Algoritmo de Seleção visa minimizar os dados de entrada do algoritmo de classificação de acordo com o necessário para o mesmo alcançar o resultado ótimo. O algoritmo genético (AG) é uma ferramenta que tem como objetivo encontrar soluções em problemas de otimização. Algoritmos genéticos usam métodos inspirados pela biologia evolutiva como seleção natural, recombinação, hereditariedade e mutação (ou *crossing over*) (Mathworks.com, 2013).

A fase operacional do método proposto está ilustrada na Figura 1(b) e consiste em normalizar os dados e classificá-los de acordo com os *clusters* definidos pelo algoritmo *k-means* e a partir do algoritmo AD. Na fase operacional apenas as variáveis selecionadas pelo AG são utilizadas. O resultado da classificação enquadra o paciente em um dos dois grupos de risco: (i) alto ou (ii) baixo. Se o paciente for classificado como baixo risco, avalia-se um novo paciente. Se o paciente for classificado como alto risco, devem-se tomar ações de cuidados para a prevenção do pé diabético. Estas ações devem ser definidas pela equipe de saúde local.

#### 4. RESULTADOS

Com o objetivo de verificar a relação e distribuição dos dados simulados, foi utilizado o algoritmo Dendrograma, onde se obtém a ilustração do arranjo de agrupamentos. Na Figura 2 verifica-se a divisão dos 30 pacientes simulados em dois grupos de 15 pacientes cada, o que comprova a diferença entre os dois grupos.

A Figura 3 mostra o gráfico *silhouettes* obtido para o agrupamento realizado pelo *k-means* considerando-se 2 *clusters*. O gráfico apresenta os *clusters* (eixo vertical) e a quantidade de eventos que cada *cluster* possui, seguido pelas disposições do grupo representado pelo valor da *silhouettes* (eixo horizontal). Maiores valores de *silhouettes* apontam para *clusters* mais ‘fortes’.

Uma forma quantitativa de avaliar os *clusters*, ou seja, escolher o número de *clusters*, usando o método *silhouettes*,

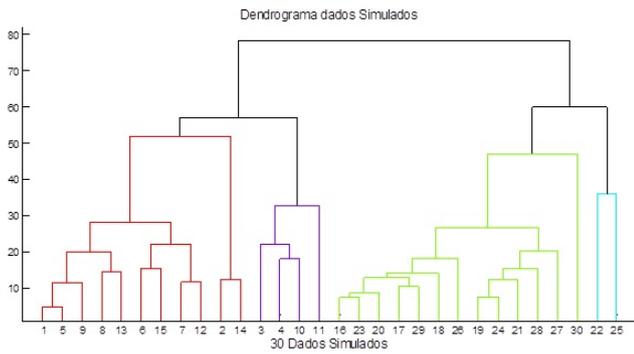


Figura 2. Dendrograma dos 30 dados Simulados.

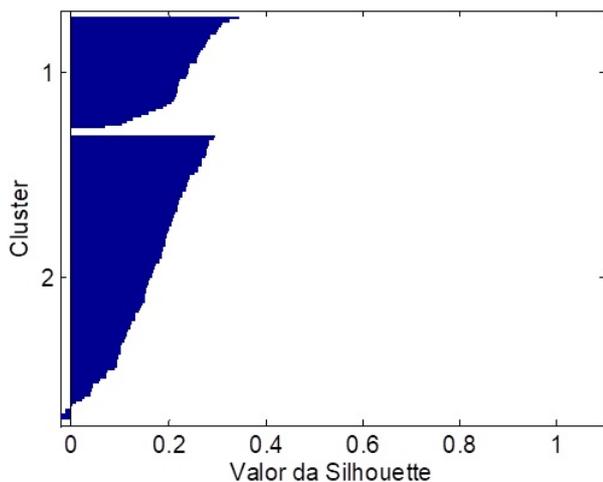


Figura 3. Gráfico *Silhouettes* para  $k=2$  clusters

é utilizar a comparação entre as médias das *silhouettes* obtidas para cada caso. A Tabela 2 mostra essa comparação para 2, 3, 4 e 5 clusters. Observa-se que o valor da *silhouettes* diminui com o aumento do número de clusters. O gráfico da *silhouettes* para 3, 4 e 5 clusters não é apresentado por simplificação.

Tabela 2. Escolha do número de clusters.

Número de Clusters $k$	Média das <i>Silhouettes</i>
2	$0,18 \pm 0,01$
3	$0,16 \pm 0,01$
4	$0,14 \pm 0,01$
5	$0,12 \pm 0,02$

Após a verificação dos clusters, o classificador Árvore de Decisão foi aplicado aos 153 dados reais agrupados pelo *k-means* como base de treinamento. A Figura 4 mostra a árvore de decisão obtida, em que todas as 30 variáveis foram apresentadas ao algoritmo árvore de decisão. Observe que o algoritmo utilizou apenas duas variáveis do banco de dados, descartando as demais. Uma vez projetado o classificador utilizando os dados reais, o banco de dados simulados foi apresentado aos mesmos para medir a eficiência. A Tabela 3 apresenta os resultados da classificação dos dados simulados.

A Tabela 3 mostra que, considerando-se a classificação para os 2 clusters a partir dos 30 dados de entradas simuladas, o classificador utilizado não foi capaz de separar o grupo de pacientes de alto risco do grupo de pacientes

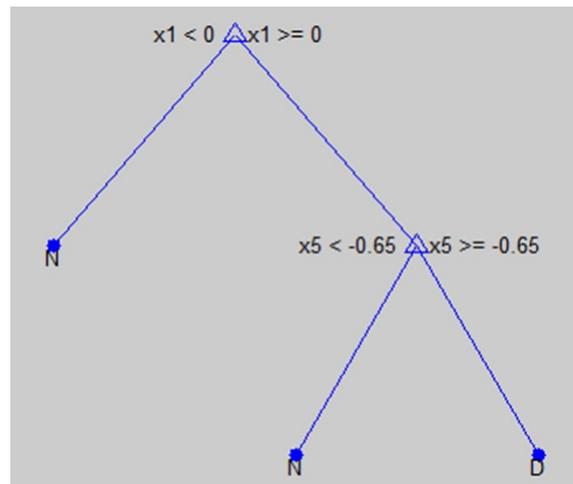


Figura 4. Classificação da Árvore de Decisão Considerando 30 entradas.

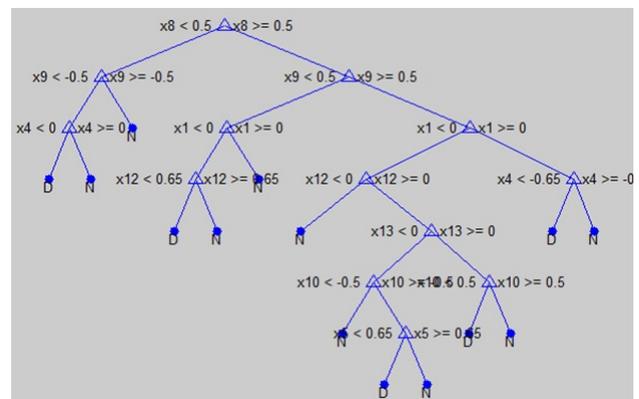


Figura 5. Classificação da Árvore de Decisão Considerando 13 entradas.

de baixo risco. A AD gera uma árvore não muito bem definida, conforme Figura 4, em que apenas duas variáveis do banco de dados são utilizadas.

O Algoritmo Genético foi aplicado para seleção de entradas do classificador AD, considerando-se o banco de dados reais (conjunto de treinamento). Foram selecionadas 13 entradas (Estado Civil, Ocupação, Escolaridade, Tipo de tratamento, Como corta as unhas dos pés, O que usa pra lavar os pés, Hábito de lavar os pés, Usa creme hidratante nos pés, Verifica o calçado por dentro antes de usar, Atitude quando percebe alteração nos pés, Aspecto interno do calçado, Hora do dia que sai pra comprar sapatos novos, Já percebeu alteração nos pés), e um aumento significativo na estrutura da árvore foi observada, conforme mostra a Figura 5. Assim, percebe-se que o Classificador conseguiu melhor distinguir os dados e assim classificá-los em 2 grupos, conforme mostra a Tabela 4.

Com essa classificação, assume-se que os pacientes (do banco de dados reais) enquadrados no Grupo 1 são de

Tabela 3. Classificação (2 clusters).

Classificação Dados Simulados para 2 Grupos	Classificação	
	Grupo 1	Grupo 2
Alto Risco	6	9
Baixo Risco	4	11

Tabela 4. Classificação Com AG.

Classificação Dados Simulados utilizando AG		
	Grupo 1	Grupo 2
Alto Risco	14	1
Baixo Risco	1	14

alto risco e os pacientes enquadrados no Grupo 2 são de baixo risco de desenvolver o pé diabético. Portanto, com esta abordagem detectou-se que 43 pacientes dos 153 foram enquadrados no Grupo de alto risco e, conseqüentemente, merecem maior atenção da equipe de saúde de forma a evitar o desenvolvimento do pé diabético.

A identificação oportuna de casos do pé diabético favorece o estabelecimento de vínculos entre os pacientes e as Unidades Básicas de Saúde, o que é imprescindível para o sucesso do controle da diabetes.

Entre as vantagens do acompanhamento e controle do diabetes no âmbito da atenção básica estão a possibilidade de evitar o surgimento de complicações, assim como de evitar o agravamento destas ocorrências, reduzindo tanto o número de internações hospitalares quanto a mortalidade relacionada às doenças cardiovasculares, entre outras complicações. É consenso geral entre endocrinologistas e infectologistas que a principal medida no tratamento do pé diabético é a detecção precoce, alcançando-se mais de 90% de sucesso para as úlceras que recebem manejo adequado, incluindo alívio da pressão local, tratamento das infecções e revascularização quando indicada.

## 5. CONCLUSÃO

Este trabalho propôs um sistema automático para identificar pacientes diabéticos que possuem alto risco de desenvolver o pé diabético. Foram exploradas duas técnicas: i) Árvore de Decisão e ii) o algoritmo genético. O Algoritmo Genético teve o propósito de melhorar os resultados e minimizar o impacto no classificador de variáveis irrelevantes. Foram utilizados dados reais coletados em Unidades Básicas de Saúde e dados simulados. O método alcançou um resultado satisfatório, apresentando acurácia superior a 90%. Para a obtenção destes resultados foram levadas em consideração apenas informações sobre o âmbito social e de autocuidado do paciente.

Como propostas futuras os autores pretendem incorporar às variáveis de entrada do sistema, informações sobre o nível de glicose do paciente e histórico de exames realizados ao longo do ano. O sistema será então implementado em Unidades Básicas de Saúde para ser testado de forma mais efetiva. Nesta fase, um ponto importante será verificar se um paciente uma vez classificado com alto risco migrará para o grupo de baixo risco após o acompanhamento sistemático da equipe de saúde.

## 6. AGRADECIMENTOS

Os autores agradecem à Fapemig, ao CNPq e à Prefeitura do Município onde os dados foram coletados.

## REFERÊNCIAS

Aha, D.W., Kibler, D., and Albert, M.K. (1991). Instance-based learning algorithms. *Machine learning*, 6(1), 37–66.

- Antonelli, D., Baralis, E., Bruno, G., Cerquitelli, T., Chiusano, S., and Mahoto, N. (2013). Analysis of diabetic patients through their examination history. *Expert Systems with Applications*, 40(11), 4672–4678.
- Appuhamy, J.R.N., Kebreab, E., and France, J. (2013). A mathematical model for determining age-specific diabetes incidence and prevalence using body mass index. *Annals of epidemiology*, 23(5), 248–254.
- 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.
- Breiman, L., Friedman, J.H., Olshen, R.A., and Stone, C.J. (1984). Classification and regression trees. Belmont, ca: Wadsworth. *International Group*, 432.
- Ekóé, J.M., Rewers, M., Williams, R., and Zimmet, P. (2008). *The epidemiology of diabetes mellitus*. John Wiley & Sons.
- Espeland, M.A., Bray, G.A., Neiberg, R., Rejeski, W.J., Knowler, W.C., Lang, W., Cheskin, L.J., Williamson, D., Lewis, C.B., Wing, R., et al. (2009). Describing patterns of weight changes using principal components analysis: results from the action for health in diabetes (look ahead) research group. *Annals of epidemiology*, 19(10), 701–710.
- Ferrero, C.A. (2009). *Algoritmo kNN para previsão de dados temporais: funções de previsão e critérios de seleção de vizinhos próximos aplicados a variáveis ambientais em limnologia*. Ph.D. thesis, Universidade de São Paulo.
- Gagliardi, F. (2011). Instance-based classifiers applied to medical databases: diagnosis and knowledge extraction. *Artificial Intelligence in Medicine*, 52(3), 123–139.
- Game, F., Hincliffe, R., Apelqvist, J., Armstrong, D.G., Bakker, K., Hartemann, A., Löndahl, M., Price, P.E., and Jeffcoate, W. (2012). A systematic review of interventions to enhance the healing of chronic ulcers of the foot in diabetes. *Diabetes/metabolism research and reviews*, 28, 119–141.
- Green, A.J., Fox, K.M., Grandy, S., Group, S.S., et al. (2012). Self-reported hypoglycemia and impact on quality of life and depression among adults with type 2 diabetes mellitus. *Diabetes research and clinical practice*, 96(3), 313–318.
- Jeffcoate, W. (2005). The incidence of amputation in diabetes. *Acta Chirurgica Belgica*, 105(2), 140–144.
- Karegowda, A.G., Jayaram, M., and Manjunath, A. (2012). Cascading k-means clustering and k-nearest neighbor classifier for categorization of diabetic patients. *International Journal of Engineering and Advanced Technology*, 1(3), 147–151.
- Karthikesalingam, A., Holt, P., Moxey, P., Jones, K., Thompson, M., and Hincliffe, R. (2010). A systematic review of scoring systems for diabetic foot ulcers. *Diabetic Medicine*, 27(5), 544–549.
- 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.
- Kitsantas, P. (2009). Profiling overweight/obesity among preschoolers: A data mining approach. *Annals of Epidemiology*, 9(19), 661–662.
- Lee, M., Gatton, T.M., and Lee, K.K. (2010). A monitoring and advisory system for diabetes patient mana-

- gement using a rule-based method and knn. *Sensors*, 10(4), 3934–3953.
- Linden, R. (2006). *Algoritmos genéticos: uma importante ferramenta da inteligência computacional*. Brasport.
- Mathworks.com (2013). Classification using nearest neighbors. URL <http://www.mathworks.com/help/stats/classification-using-nearest-neighbors.html?searchHighlight=knn>.
- Organization, W.H. (2018). The 10 leading causes of death in the world, 2000 and 2016. *Fact sheet*, (310).
- Santos A., Pereira B., S.J.M.M.F.K.A. (2003). Árvore de classificação e redes neurais artificiais: Uma aplicação a predição e tuberculose pulmonar. *Proceedings of the VI Brazilian Conference on Neural Networks*, 427–432.
- Tennvall, G.R. and Apelqvist, J. (2000). Health-related quality of life in patients with diabetes mellitus and foot ulcers. *Journal of Diabetes and its Complications*, 14(5), 235–241.