



Técnica *boosting*: apoio à decisão na Atenção Primária à Saúde

Boosting technique: decision support in Primary Health Care

Impulsar técnica: soporte de decisibones en atención primaria de salud

Amanda Amaiy Pessoa Salerno¹, Rodrigo Pinheiro de Toledo Vianna², Ronei Marcos de Moraes²

RESUMO

Descritores: Avaliação nutricional; Atenção primária à saúde; Tomada de decisão; Política pública

Objetivo: Criar um modelo de apoio à tomada de decisão, fundamentado na técnica computacional de *boosting*, utilizando o algoritmo *Adabboost.M1* junto ao **Método:** Base de uma Rede Neural Artificial, para apoio à decisão na atenção nutricional no contexto da Atenção Primária à Saúde. **Métodos:** estudo seccional de base populacional representativa das unidades básicas de saúde dos 27 estados federativos do Brasil, com unidade amostral de 29.778 unidades. Os dados são provenientes do banco de dados do 2º ciclo de Avaliação Externa do Programa de Melhoria do Acesso e da Qualidade na Atenção Básica realizado em 2013. **Resultados:** A Rede Neural Artificial gerada junto ao algoritmo *Adaboost.M1* obteve 99.36% de acertos na decisão, a partir da predição da adequação dos serviços de saúde. **Conclusão:** Este modelo demonstrou auxiliar na tomada de decisões em atenção nutricional no contexto da Atenção Primária à Saúde.

ABSTRACT

Keywords: Nutritional assessment; Primary health care; Decision making; Public policy

Objective: To create a decision making support model based on the boosting algorithm using the *Adabboost.M1* algorithm along with an Artificial Neural Network, for decision support in nutritional care in the context of Health Primary Care. **Methods:** Cross-sectional population-based study representative of basic health units of the 27 federal states of Brazil, with sample unit of 29,778 units. Data are from the 2nd External Evaluation Cycle Data Access Improvement Programme and Quality in Primary Care database held in 2013. **Results:** The Artificial Neural Network generated by the algorithm *Adaboost.M1* had an accuracy of 99.36% regarding the prediction of suitability of health services. **Conclusion:** This model was adequate in making decisions on nutritional care in the context of primary health care.

RESUMEN

Descriptores: Evaluación nutricional; Atención primaria de salud; Toma de decisiones; Política pública

Objetivo: Crear un modelo para apoyar la toma de decisiones, basado en la técnica computacional de impulsar el uso de algoritmo *Adabboost.M1* con el método básico de una Red Neuronal Artificial para apoyar las decisiones en el cuidado nutricional en el contexto de la atención primaria de salud. **Métodos:** Estudio transversal de la unidad básica de salud basados en la población representativas de los 27 estados federales de Brasil, con unidad de muestra de 29,778 unidades. Los datos son de la orilla del Programa de Mejora de Evaluación del Ciclo 2º externa de acceso a datos y la calidad en la atención primaria celebrada en 2013. **Resultados:** Artificial algoritmo de red neuronal generada por el *Adaboost.M1* obtuvo 99,36% de la decisión correcta a partir de la predicción de la adecuación de los servicios de salud. **Conclusión:** Este modelo se ha mostrado ayudar en la toma de decisiones sobre la atención nutricional en el contexto de la atención primaria de salud.

¹ Mestranda do Programa de Pós-Graduação em Modelos de Decisão e Saúde do Departamento de Estatística da Universidade Federal da Paraíba - UFPB, João Pessoa (PB), Brasil.

² Professor efetivo do Programa de Pós-Graduação em Modelos de Decisão e Saúde, Departamento de Estatística da Universidade Federal da Paraíba - UFPB, João Pessoa (PB), Brasil.

INTRODUÇÃO

Os serviços de Atenção Primária à Saúde (APS) são conhecidos pela sua extensão e heterogeneidade no território nacional, no qual numa conjuntura de investimento na institucionalização de uma cultura avaliativa, dispõe a organização das ações produzidas no cotidiano dos serviços como um eixo prioritário para avaliação⁽¹⁾. As dimensões essenciais e relevantes para a conquista de bons resultados na APS, são o acesso, a continuidade do cuidado, coordenação do cuidado e integralidade ou abrangência do cuidado/compreensiveness⁽²⁾.

Neste contexto, as Doenças Crônicas Não Transmissíveis (DCNT) constituem uma ameaça para a saúde, na qual a Organização Mundial da Saúde (OMS) considera cerca de 36 milhões as mortes anuais ocasionadas por esse grupo de doenças, e estas são causadas a partir de efeitos negativos advindos do processo de globalização, da urbanização rápida, da vida sedentária, como também dos maus hábitos alimentares⁽³⁾. Portanto a alimentação saudável vem garantindo espaço na construção das políticas públicas e, atualmente, sua promoção está prevista em diversas políticas e programas nacionais⁽⁴⁾.

As ações de alimentação e nutrição, promovidas pelo Ministério da Saúde (MS) no Brasil e desenvolvidas pelas equipes da APS, são direcionadas para a promoção da alimentação saudável e adequada, prevenção de agravos nutricionais e de Vigilância Alimentar e Nutricional⁽⁵⁾. Apesar de grande parte dos países implementar programas e ações de alimentação e nutrição, em geral ainda não são realizadas ações institucionizadas de monitoramento e avaliação voltadas a aperfeiçoá-las a longo prazo⁽⁶⁾.

Assim sendo, direcionado ao fortalecimento da APS, o Programa de Melhoria do Acesso e da Qualidade na Atenção Básica (PMAQ-AB), instituído pela portaria de nº 1.654 GM/SM do dia 19 de julho de 2011, busca induzir, monitorar e avaliar os processos de trabalho das equipes de saúde aderidas ao programa e os resultados alcançados por elas. Logo, a Coordenação Geral da Política de Alimentação e Nutrição (CGPAN) do MS, têm buscado a inclusão de indicadores de qualidade nos instrumentos de avaliação do programa que permitam o diagnóstico sobre a implementação de suas ações estratégicas para a atenção nutricional⁽⁷⁾.

O PMAQ-AB já possui uma matriz de pontuação que pode ser usada na certificação das equipes de saúde, pontuada a partir do valor de cada variável, das suas subdimensões e dimensões. Entretanto, isso foi realizado apenas para as variáveis referentes ao padrão de qualidade do serviço orientado a uma avaliação geral do PMAQ-AB⁽⁷⁾. No caso da atenção nutricional, nem todas as variáveis foram elegidas como padrão de qualidade para certificação. Por consequência, a atenção nutricional no contexto da Atenção Primária à Saúde não pode se servir desse modelo de pontuação.

Vários estudos relativos à predição de situações de diagnósticos em saúde envolvem o apoio à decisão em saúde. A disponibilidade de uma grande quantidade de

dados digitais, como por exemplos dados governamentais, contribui para o avanço desses métodos, promovendo também a melhoria de serviços⁽⁸⁾. Entretanto, no contexto da criação e aplicação de modelos de apoio à decisão, não foram encontrados estudos na área de avaliação da adequação dos serviços de saúde e da atenção nutricional na APS.

Nessa perspectiva o trabalho de Ichikawa e colaboradores⁽⁹⁾, analisou o comportamento de um método com capacidade preditiva para o diagnóstico da hiperuricemia, no qual utiliza um gradiente boosting que combina árvores de decisão, no sentido de resolver problemas de regressão e classificação. Porém neste estudo é utilizado o algoritmo Adaboost.M1, que segundo Freund e Schapire⁽¹⁰⁾, é também um algoritmo boosting, técnica esta utilizada para melhorar a acurácia dos algoritmos de predição.

O Adaboost foi projetado para problemas de classificação e pode ser utilizado em combinação com qualquer outro algoritmo, trabalhando apenas com problemas de classes nominais. O mesmo apresenta algumas propriedades que o fazem mais prático, já que ele não depende de um conhecimento prévio das predições alcançadas por outros métodos. Em geral, seus resultados finais são superiores ao método base aplicado originalmente⁽¹¹⁾. Dessa forma, optou-se pelo algoritmo Adaboost, devido ao seu potencial de flexibilidade e simplicidade para ser efetivado em diversos cenários.

Portanto, este trabalho tem como objetivo criar um modelo de apoio à tomada de decisão, fundamentado na técnica computacional de boosting, utilizando o algoritmo Adaboost.M1 junto ao método base Multilayer Perceptron, empregando variáveis sobre as ações de alimentação e nutrição na APS no Brasil, provenientes do banco de dados do PMAQ-AB, como referências preditoras para a situação da atenção nutricional, e testando o modelo na identificação da mesma.

O presente estudo deve proporcionar conhecimentos que auxiliem os gestores e profissionais de saúde na busca de estratégias que facilitem a tomada de decisão na Atenção Nutricional proporcionada pela APS. Por fim, a elaboração do modelo de apoio à decisão possibilitará a avaliação e monitoramento das ações de alimentação e nutrição que são desenvolvidas.

Ademais, além do seu baixo custo e rapidez, o modelo poderá ser replicado em outros locais e contribuir para fornecer dados sobre aspectos e diferenciais na atenção nutricional promovida pela APS em diversas regiões do país, utilizando-se as mesmas variáveis provenientes deste estudo.

MÉTODOS

Refere-se a um estudo seccional de base populacional, cuja unidade amostral foi de 29.778 unidades de saúde dos 27 estados federativos do Brasil, e os dados provenientes do banco de dados do 2º ciclo de Avaliação Externa do PMAQ-AB, realizado em 2013.

Inicialmente selecionou-se as variáveis sobre as ações de alimentação e nutrição do módulo II do instrumento

de dados, com base nas ações que devem ser realizadas nos serviços de saúde, e o critério de inclusão das variáveis foi determinado pelas diretrizes da Política Nacional de Alimentação e Nutrição (PNAN). O módulo em questão é referente à entrevista com profissional da equipe da APS e verificação de documentos na unidade de saúde. Na maioria das vezes o profissional da enfermagem era quem respondia, por apresentar maiores informações sobre a unidade avaliada.

Na construção do modelo de apoio à decisão foram selecionadas 19 variáveis nominais dicotômicas sobre as ações de alimentação e nutrição desenvolvidas nos serviços de saúde. Segundo essas variáveis o modelo classifica as unidades de saúde em adequada, parcialmente adequada, parcialmente inadequada e inadequada. Na Tabela 1 são apresentadas as variáveis de acordo com os eixos temáticos abordados no instrumento do PMAQ-AB.

Nessa perspectiva de criar um modelo supervisionado de apoio à decisão, as unidades foram classificadas previamente com base no instrumento de Avaliação Externa do PMAQ-AB. O instrumento apresenta padrões de qualidade estabelecidos de acordo com as normas, protocolos, princípios e diretrizes que organizam ações e práticas em saúde no contexto da APS, e é caracterizado como um dispositivo potencial para o monitoramento e avaliação da implementação de políticas públicas⁽¹¹⁾, inclusive da PNAN.

Diante disso as unidades foram classificadas segundo a realização das ações de alimentação e nutrição, sendo esta classificação prévia a 20ª variável do estudo em

questão, ou seja, a variável resposta que consiste em um agente externo, já que o modelo de apoio à decisão em questão apresenta-se como uma técnica de aprendizado supervisionado. Assim o critério utilizado para classificação seguiu a seguinte condição: se a unidade de saúde realizou mais de 80% das ações de alimentação e nutrição foi classificada como adequada, de 50 – 80% parcialmente adequada, de 30 – 50% parcialmente inadequada e menos de 30% inadequada.

Neste trabalho o algoritmo utilizado para predição da adequação dessas ações, foi o Adabost.M1, disponível no software Weka. A técnica boosting foi aplicada, na medida em que o Adaboost.M1 solicitava um método base, repetidamente, num conjunto de execuções. Um dos principais fundamentos do algoritmo é remodelar a distribuição, ou conjunto de pesos, sobre o conjunto de treinamento. Inicialmente os pesos são todos iguais, mas a cada efetuação, os pesos dos exemplos classificados incorretamente são incrementados, na medida em que o método base seja obrigado a agir com maior intensidade sobre estes exemplos no conjunto de treinamento, já a taxa de erro é aferida contando o número de predições incorretas. Ademais, uma vez que a hipótese foi obtida da iteração do algoritmo base, o Adaboost define um parâmetro que é pertencente ao conjunto dos números reais, o qual mede a importância que é dada à hipótese do algoritmo base. Para formular a hipótese final, cada hipótese gerada pelas distribuições contribui com uma certa confiança dada pelo parâmetro⁽¹⁰⁾.

Tendo em vista que a proposta principal dos essembles

Tabela 1 – Variáveis por eixo temático do Programa Nacional de Melhoria do Acesso e da Qualidade na Atenção Básica.

Variáveis	
Atenção à criança desde o nascimento até os dois anos de vida	
1	Registro sobre o estado nutricional das crianças
2	Realização das ações de Vigilância Alimentar e Nutricional
3	Avaliação e monitoração dos índices de aleitamento materno e alimentação complementar
Atenção à pessoa com obesidade	
Mensuração do peso e altura:	
4	Das crianças menores de dois anos de idade
5	Das crianças menores de dez anos de idade
6	Das gestantes
7	Dos adultos com hipertensão e diabetes
8	Dos usuários atendidos na Unidade Básica de Saúde (UBS)
9	Não realiza mensuração do peso e altura
Condutas que a equipe realiza com o usuário adulto com obesidade:	
10	Consultas de acompanhamento deste usuário na UBS
11	Atividades coletivas sobre a alimentação saudável e atividade física
12	Apoio do NASF
13	Encaminhamento para serviço especializado
14	Não realiza nenhuma conduta específica
Promoção da saúde	
Oferta de ações educativas e de promoção da saúde	
15	Aleitamento materno
16	Alimentação saudável
Programa Saúde na Escola	
Avaliação clínica:	
17	Avaliação antropométrica
18	Avaliação nutricional
Atividades de promoção e prevenção da saúde:	
19	Ações de Segurança Alimentar e promoção da alimentação saudável

(conjunto de classificadores/comitê), é através dessa combinação, aproveitar as contribuições de cada classificador, foram testadas algumas combinações, contudo, os resultados exitosos desse método são alcançados principalmente quando o método base é considerado instável, como por exemplo das redes neurais⁽¹²⁾.

Nessa perspectiva, uma Rede Neural Artificial (RNA) é um sistema de processamento de informação que apresenta algumas características de execução similar com as redes neurais biológicas⁽¹³⁾. As redes neurais são desenvolvidas com o objetivo de construir modelos matemáticos habilitados de generalizar um domínio de conhecimento específico, concedendo-nos a condição de produzir um processo artificial de aquisição do conhecimento. Desta maneira, a rede passa por um processo de aprendizagem, em que ocorre a atualização das sinapses de modo ordenado para um alcance de um objetivo desejado. O desempenho da RNA depende dos métodos de aprendizagem, já que por meio deles são concedidas condições para realizar uma medida de representação daquilo que a rede necessita aprender, dessa forma os parâmetros da rede são otimizados em relação a este aprendizado⁽¹⁴⁾.

O algoritmo clássico de aprendizagem empregado nas redes neurais é o backpropagation, que está relacionado com a atualização dos pesos sinápticos da rede, o qual baseia-se na heurística de aprendizado por correção de erro, no qual o erro é retropropagado da camada de saída, passando pelas camadas ocultas/intremediárias da RNA, por sua vez os pesos são ajustados, na medida em que a resposta obtida se aproxime do padrão da resposta desejada⁽¹⁵⁾. Porém, ainda existem problemas na utilização desse algoritmo de treinamento, como por exemplo, o da generalização. Diante disso, uma tentativa para solucionar este problema é aplicar o algoritmo AdaboostM1, que melhora a capacidade de generalização do aprendizado de retropropagação do erro^(14,16).

Diante disso, para a escolha do método base, o trabalho em questão analisou o algoritmo Multilayer Perceptron, caracterizado como uma implementação RNA, isoladamente e em combinação com o Adaboost.M1.

Para concepção do modelo de RNA foi empregado o Multilayer Perceptron com treinamento por retropropagação de erros (backpropagation), o qual fundamenta-se em produzir uma adaptação sistemática

dos pesos na rede. As redes neurais apresentam diversas opções de configuração, o que constitui automaticamente alguns resultados possíveis. Após algumas tentativas de customização da rede, foram utilizados os parâmetros do software Weka, com taxa de aprendizado de 0,2, taxa de momentum de 0,3 e número de ciclos de execução de 500.

Dessa maneira, o algoritmo Adaboost.M1 foi utilizado neste estudo para melhorar o aprendizado da arquitetura Multilayer Perceptron, de uma RNA treinada com o algoritmo de aprendizado backpropagation. Esta combinação serviu para modelar os dados sobre as ações de alimentação e nutrição na APS, apoiando a tomada de decisão sobre a situação da atenção nutricional, na qual a técnica boosting ajudou a decidir sobre a situação de adequação ou inadequação na realização das ações desenvolvidas nas unidades de saúde.

A ferramenta utilizada foi o Waikato Environment for Knowledge Analysis (WEKA), versão 3.6.3, pode ser amplamente utilizada em atividades de aprendizado de máquina. É um software de domínio público e que disponibiliza diversos algoritmos de Inteligência Artificial⁽¹⁷⁾, apresentando implementações de algoritmos para a classificação, associação e mineração de regras, integrando interfaces gráficas e utilitários de visualização para exploração de dados e avaliação do algoritmo⁽¹⁸⁾.

De acordo com as normas éticas em pesquisa envolvendo seres humanos, o estudo foi submetido e aprovado pelo Comitê de Ética em Pesquisas em Seres Humanos da Ensp/ Fiocruz, e recebeu o parecer N° 32.012 em 06/06/2012. Os autores pesquisadores integrantes da Universidade Federal da Paraíba (UFPB) participaram direta ou indiretamente da avaliação externa do PMAQ-AB, programa financiado pelo Departamento de Atenção Básica do Ministério da Saúde, e declaram não haver conflito de interesses.

RESULTADOS E DISCUSSÃO

Na Tabela 2 observa-se que a RNA apresentou um maior desempenho quando combinada ao Adaboost.M1, apresentando o coeficiente Kappa de 0,9878. Ademais, quando a RNA foi gerada de forma isolada observou-se um menor desempenho, com o Kappa de 0,8318, indicando que o algoritmo Adaboost.M1 influenciou na melhora dos resultados.

Tabela 2 – Comparação do desempenho da combinação do Adaboost.M1 com o classificador base e do classificador base isolado

Classificadores base	Testes com o <i>Adaboost.M1</i>		Testes isolados	
	Taxa de acerto	Kappa	Taxa de acerto	Kappa
Trees				
Decision Stump	63,2816%	0		
Hoeffding Tree	92,2795%	0,8445		
J48	92,9545%	0,8671		
Fuctions				
Multilayer Perceptron	99,3653%	0,9878	91,9773%	0,8318
SMO	92,6557%	0,8603		
Bayes				
Naive Bayes	91,8027%	0,8434		

De acordo com esses resultados, a utilização de técnica fundamentada na combinação de métodos apresentou-se como uma abordagem mais adequada. Além de que, a partir da análise desses testes, o método boosting apresentou uma eficiência superior aos demais, algo que foi constatado no trabalho de Lopes e colaboradores⁽¹⁹⁾, no qual há uma comparação das taxas de acerto de alguns métodos baseados em um classificador simples de árvore

de decisão, a partir do algoritmo C4.5, e em técnicas de combinação de classificadores, como o bagging e o boosting, aplicados em bases de dados da área da saúde.

A análise do modelo com combinação e de forma isolada, foi realizada a partir do coeficiente de Kappa, que é uma medida robusta, comumente utilizada como uma medida de associação para descrever e avaliar o grau de confiabilidade e precisão/ concordância entre as

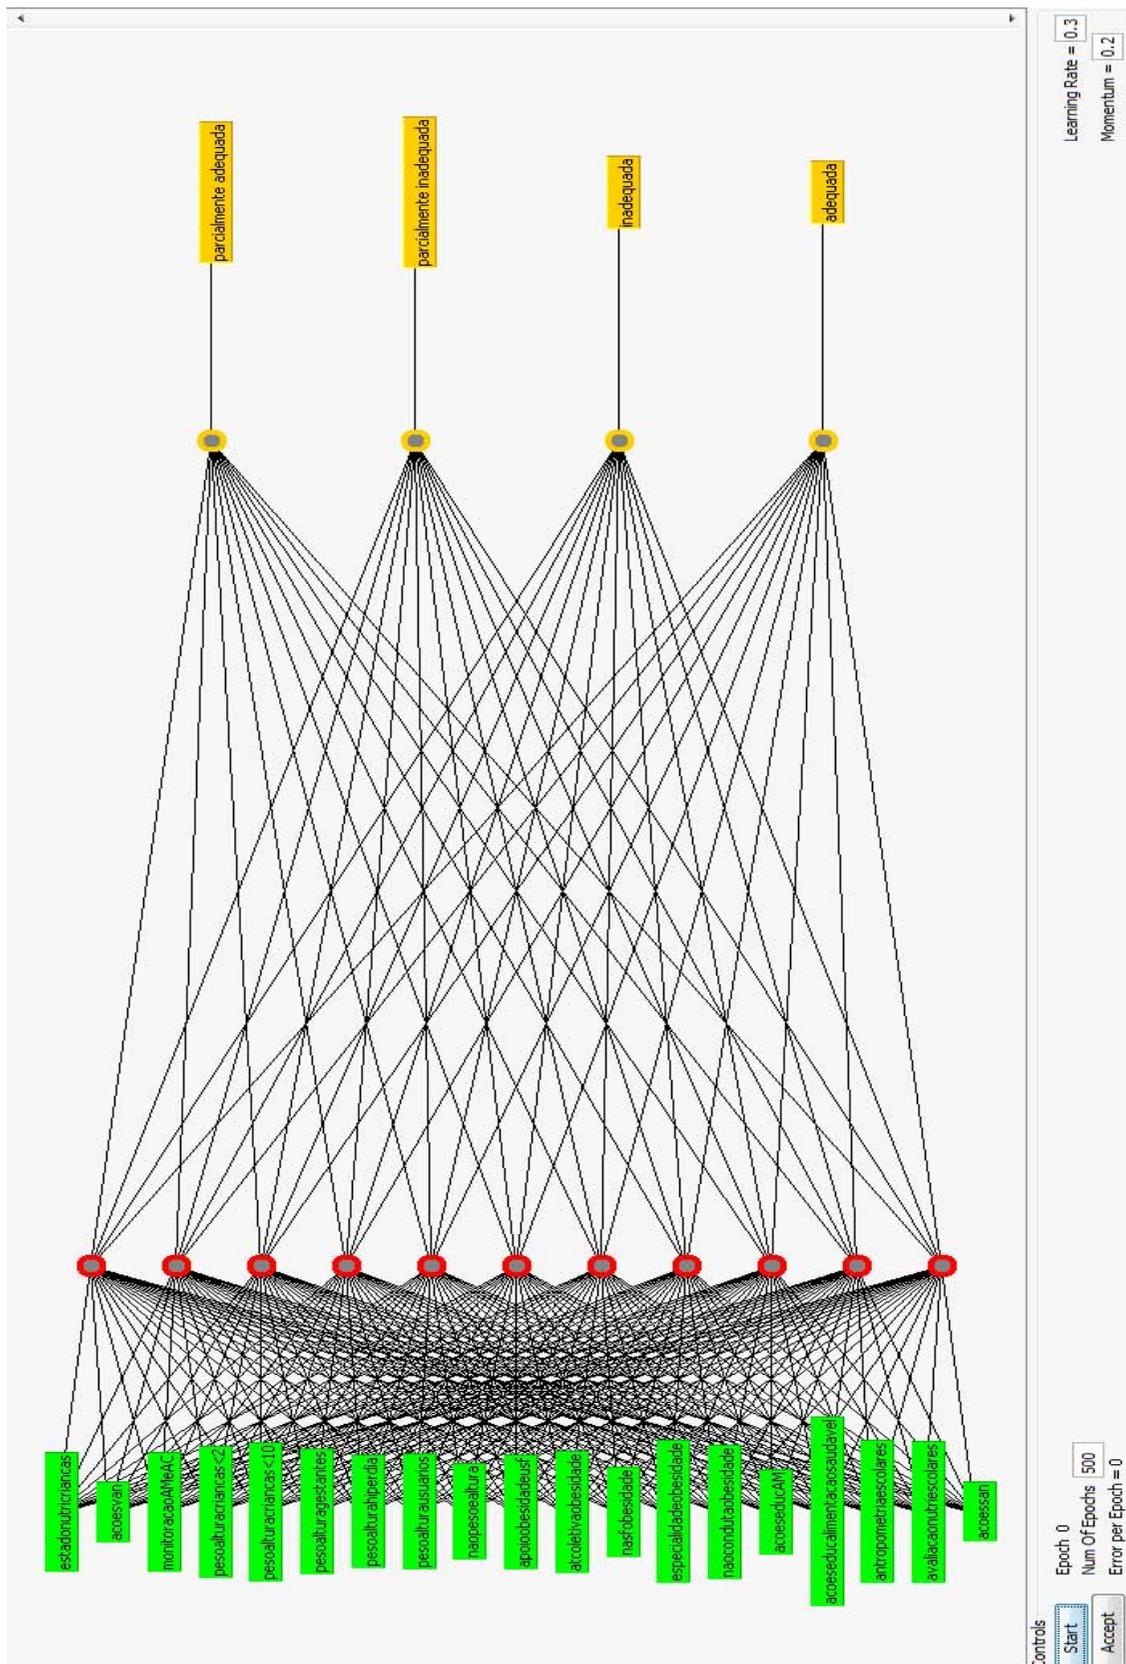


Figura 1 – Modelo de Rede Neural Artificial utilizada

classificações⁽²⁰⁾. Pode variar de 0 a 1, onde $k \leq 0,2$: péssimo; $0,2 < k \leq 0,4$: razoável; $0,4 < k \leq 0,6$: bom; $0,6 < k \leq 0,8$: muito bom e $0,8 < k \leq 1$: excelente⁽²¹⁾.

A Figura 1 apresenta a construção da rede neural, na qual foram utilizadas as 19 variáveis sobre as ações de alimentação e nutrição que devem ser realizadas nas 29.778 unidades de saúde como dados de entrada, dicotomizadas em sim – 1 e não – 0. O modelo foi concebido com 4 neurônios na camada de saída, 11 neurônios na camada oculta e os dados de saída que informam sobre a situação da atenção nutricional, ou seja, da classificação de adequação, parcial adequação, parcial inadequação ou inadequação das unidades, no que diz respeito a realização das ações de alimentação e nutrição. Por sua vez, o algoritmo Adaboost.M1 foi aplicado na classificação das unidades de saúde, melhorando o desempenho do aprendizado através de um processo iterativo.

De acordo com os resultados da matriz de confusão, matriz de acertos e erros associados à previsão do modelo, foi revelado que a classificação apresentou uma frequência percentual de 99,36% de acertos contra 0,63% de erro na decisão, indicando que a ação do Adaboost.M1 no treinamento finalizou quando a taxa de acerto desejada foi atingida e o índice de erros apresentou o mínimo desejado.

Ademais, a Figura 2 apresenta as classes a, b, c e d da matriz, das 29.778 unidades analisadas, na qual a técnica boosting classificou corretamente 29.589; acertou mais quando classificou as 18.932 unidades como parcialmente adequadas; do total de unidades a técnica classificou erroneamente 189; errou mais quando classificou as unidades como parcialmente inadequadas, no qual das 70 que eram pra ser classificadas como parcialmente inadequadas, 53 foram classificadas como parcialmente adequadas e 17 como inadequadas.

Quando a situação era de adequação o modelo acertou 7414 vezes, ocorrendo 29 erros na decisão; na ocasião de parcialmente adequado houveram 18932 acertos e 62 erros; a classificação de parcialmente inadequado obteve 2861 acertos e 70 erros, caracterizando uma maior quantidade de erros quando comparada aos demais; e finalmente quando considerado inadequado apresentou 322 acertos e 28 erros, sendo considerado como classificação que apresentou menor erro.

Porém, na análise de erros, o erro considerado de maior gravidade foi quando o método de boosting,

classificou 53 vezes unidades parcialmente inadequadas em serviços parcialmente adequados, indicando que o algoritmo de classificação Adaboost.M1 com o classificador base da RNA confundiu-se na identificação. O índice Kappa constatado foi de 0,98, confirmando um padrão de classificação excelente pelo Weka, na diferenciação entre as quatro classificações.

Neste trabalho, o algoritmo Adaboost.M1, é utilizado para melhorar a aprendizagem da arquitetura Perceptron de Múltiplas Camadas, ou seja, RNA treinada com o algoritmo de aprendizado conhecido como retropropagação do erro, para conseguir melhores resultados de classificação em detrimento da complexidade computacional, superando os problemas de categorização⁽¹⁶⁾.

No apoio ao diagnóstico do câncer e na detecção e classificação de microcalcificações em mamografia digital, Oliveira e colaboradores⁽²²⁾ construíram um software baseado na inteligência artificial do algoritmo Adaboost conjuntamente com a RNA. O sistema obteve taxa de acerto de 94,5%, a partir de uma série de tentativas de mudanças na configuração da topologia da RNA, contudo o estudo não analisa a rede neural isoladamente, não especificando o quanto o Adaboost melhorou a rede.

Porém, no estudo de Alves e colaboradores⁽²³⁾ foi desenvolvido um sistema de comitê empregando técnicas de agrupamento, fundamentado também em redes neurais para suporte à decisão quanto ao isolamento de pacientes suspeitos de diagnóstico da tuberculose. Neste trabalho o desempenho dos comitês em relação à implementação do Adaboost, obteve valores de especificidade superiores, sinalizando-se ser mais relevante no apoio ao isolamento desses pacientes.

No contexto da atenção nutricional, a matriz analisada neste estudo, caracterizou um maior percentual de unidades parcialmente adequadas, no que corresponde ao desenvolvimento das ações de alimentação e nutrição no contexto da APS. Apesar da promoção da alimentação saudável ser uma das práticas mais prevalentes nas Unidades Básicas de Saúde (UBS), as ações previstas na PNAN não foram totalmente implementadas no contexto da APS, como podemos observar na matriz de confusão aqui exposta, que ainda constatou um percentual de muitas unidades consideradas parcialmente inadequadas. Embora existam vários esforços e diretrizes para implementar ações de alimentação e nutrição na APS, os resultados deste

=== Confusion Matrix ===

a	b	c	d	<-- classified as
18932	11	51	0	a = parcialmente adequado
53	2861	0	17	b = parcialmente inadequado
29	0	7474	0	c = adequado
1	27	0	322	d = inadequado

Figura 2 – Matriz de Confusão que apresenta os acertos e erros da classificação

estudo enfatiza a importância de qualificar e melhorar estas ações nas UBS, como também de que é relevante desenvolver sistemas inteligentes de apoio à decisão no contexto da avaliação da atenção nutricional na APS.

Ainda que, a maioria das políticas públicas sejam acompanhadas e avaliadas devido seus requisitos legais, existem grandes deficiências em relação às estratégias avaliativas, principalmente devido as limitações encontradas na qualidade e disponibilidade dos dados no contexto da saúde⁽²⁴⁾. O progresso na avaliação do êxito das ações de nutrição só pode ser assumido quando os programas, como o PMAQ-AB, assegurarem a disponibilidade de dados adequados e que reflitam nos resultados apropriados em pelo menos médio prazo nos serviços de saúde, assegurando avanços para a tomada de decisão.

Entretanto é importante destacar que o instrumento utilizado na Avaliação Externa do PMAQ-AB, ainda apresenta alguns limites quanto à sua validade interna, ou seja, validade de construto, na medida em que a maioria das questões analisadas neste trabalho, não necessitou de comprovação da documentação por parte dos profissionais entrevistados⁽²⁵⁾. Além disso, o banco de dados utilizado apresenta alguns missings, que são considerados como os dados incompletos ou faltantes, o que é uma limitação em pesquisas, principalmente na área da saúde⁽²⁶⁾. Outra questão é que várias das variáveis presentes neste estudo pertencem somente ao 2º ciclo do PMAQ-AB.

Foi pensando na importância da criação de métodos exitosos em prever a situação da atenção nutricional das unidades de saúde da APS, que foi proposta uma técnica boosting utilizando-se o modelo de rede neural para apoio à decisão, podendo ser aplicada com informações de outras fontes de dados para prever a situação dado cuidado nutricional, elevando-se a probabilidade de se

alcançar sucesso nas decisões dos gestores nas três esferas governamentais. Os resultados levantados neste trabalho também poderão auxiliá-los a terem um olhar particular sobre as práticas direcionadas a alimentação e nutrição, de forma a fornecer subsídios para melhorar a efetivação destas nos serviços de saúde.

CONCLUSÃO

A proposta do modelo baseado na técnica boosting, apresentou êxito em seu desempenho, com 99.36% de acertos na decisão da classificação das unidades de saúde e coeficiente Kappa de 0,98, podendo ser empregado como instrumento de apoio para prognosticar a situação da atenção nutricional, no que diz respeito, a realização ou não das ações de alimentação e nutrição por parte das unidades de saúde da APS, segundo a referência política e normativa da PNAN.

Nesse sentido, o modelo consegue decidir, a partir da classificação da unidade (adequada, parcialmente adequada, parcialmente inadequada ou inadequada), sobre o reconhecimento e distinção entre as unidades que realizam as ações daquelas que não realizam, como também seu nível de realização, em sua totalidade ou parcialidade, confirmando que este sistema de apoio à tomada de decisão dos gestores é uma ferramenta útil para o monitoramento e avaliação da atenção nutricional nas unidades de saúde.

AGRADECIMENTOS

Os autores agradecem o apoio e financiamento, desta pesquisa, à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão da bolsa de estudo.

REFERÊNCIAS

1. Donabedian A. The quality of care: how can it be assessed? *Arch Pathol Lab Med.* 1997;121(11):1145-50.
2. Kringos DS, Boerma WG, Hutchinson A, van der Zee J, Groenewegen PP. The breadth of primary care: a systematic literature review of its core dimensions. *BMC Health Serv Res.* 2010;10(1):1-13.
3. World Health Organization-WHO. Global status report on non communicable diseases 2010. World Health Organization; 2011.
4. Castro IR. Desafios e perspectivas para a promoção da alimentação adequada e saudável no Brasil. *Cad. Saúde Pública.* 2015;31(1):1-3.
5. Alencar B, Pereira M, Ramos N. Curso de Autoaprendizado – Programa Nacional de Melhoria do Acesso e da Qualidade na Atenção Básica (PMAQ-AB). Realização: Ministério da Saúde, Organização Pan-Americana da Saúde, Observatório de Políticas de Segurança Alimentar e Nutrição e Universidade de Brasília. Brasília; 2012. [Internet] [citado 2016 jun 25]. Disponível em: http://ecos-redenutri.bvs.br/tiki-download_file.php?fileId=149
6. Carvalho AT, Almeida ER, Nilson EA, Ubarana JA, Fernández IM, Imidink M. Métodos de análise em programas de segurança alimentar e nutricional: uma experiência no Brasil. *Ciênc Saúde Colet.* 2013;18(2):309-21.
7. Fausto MCR, Souza Júnior PRB. Nota metodológica sobre a avaliação das equipes de Atenção Básica e censo das Unidades Básicas de Saúde no âmbito do Programa Nacional para Melhoria do Acesso e Qualidade da Atenção Básica. Mimeo; 2013.
8. Santos AC. Aprendizado de máquina aplicado ao diagnóstico de Dengue. In: III Encontro Nacional de Inteligência Artificial e Computacional; 2016 Out 9-12; Recife, PE. [internet]. Disponível em: <http://www.lbd.dcc.ufmg.br/colecoes/eniac/2016/059.pdf>
9. Ichikawa D, Saito T, Ujita W, Oyama H. How can machine-learning methods assist in virtual screening for hyperuricemia? A healthcare machine-learning approach. *J Biomed Inform.* 2016; 64:20-4.
10. Freund Y, Schapire RE. Experiments with a new boosting algorithm. *Proceeding of the Machine Learning Thirteenth International Conference.* 1996 Jul 3-6; Bari, Italy: Morgan Kaufmann; 1996.p.148-56.
11. García-Pedrajas N, Ortiz-Boyer D. Boosting k-nearest neighbor classifier by means of input space projection. *Exp Syst Applic.* 2009;36:10570-82.
12. Brasil. Secretaria de Atenção à Saúde. Departamento de Atenção Básica. Instrumento de Avaliação Externa do Saúde Mais Perto de Você - Acesso e Qualidade. Programa Nacional de Melhoria do Acesso e da Qualidade da Atenção Básica. [Internet]. Brasília: Ministério da Saúde, 2012. Série A. Normas e Manuais técnicos. [acesso 2015 nov 25]. Disponível em: http://189.28.128.100/dab/docs/publicacoes/geral/instrumento_coleta_avaliacao_externa.pdf
13. Dietterich TG. Ensemble methods in machine learning. *Proceeding of the First International Workshop on Multiple*

- Classifier Systems. Lecture Notes in Computer Science; 2000 Jun 21-23; Cagliari, Italy: Springer; 2000. p.1-15.
14. Fausett L. Fundamentals of neural networks: architectures, algorithms, and applications. New Jersey, USA: Prentice-Hall, Inc.; 1994.
 15. Haykin S, Lippmann R. Neural Networks: a comprehensive foundation. *Int J Neural Syst.* 1994;5(4):363-4.
 16. Skorpil V, Kamba S. Back propagation and genetic algorithms for control of the network element. In: 34th International Conference on Telecommunications and Signal Processing (TSP); IEEE; 2011 Aug 18-20; Budapest, Hungary. [internet]. Available from: <http://ieeexplore.ieee.org/xpl/mostRecentIssue.jsp?punumber=6032139>
 17. Murphey YL, Chen Z, Guo H. Neural learning using AdaBoost. In: Neural Networks, 2001. Proceedings. IJCNN'01. International Joint Conference on; IEEE; 2011. Jul. 15 - 19. Washington, DC. USA. [internet]. Disponível em: <http://ieeexplore.ieee.org/xpl/mostRecentIssue.jsp?punumber=7474>
 18. Eibe F, Mark AH, Ian HW. The WEKA Workbench. Online Appendix For "Data mining: Practical Machine Learning Tools and Techniques". 4th ed. New Zealand: Morgan Kaufmann; 2016.
 19. Witten IH, Frank E. Data Mining: practical machine learning tools and techniques. 2nd ed. San Francisco: Morgan Kaufmann; 2005.
 20. Lopes L, Scalabrin EE, Riella CL, Manfre P. Aprendizagem de máquina através de combinação de classificadores em bases de dados da área da saúde. Anais do XI Congresso Brasileiro de Informática em Saúde CBIS'2008. 2008 Nov 29 - Dez 3. Campos de Jordão - SP.
 21. Cohen J. A coefficient of agreement for nominal scales. *Educ Psychol measur.* 1960;20(1):37-46.
 22. Jinadu OT, Johnson OV. Information and communication technology as a provider of food security: design of an expert system to assist in communication where non-audible communication is expedient. Proceedings of the World Congress on Engineering. 2011 Jul 6-8. London.
 23. Oliveira WM, Matias IO, Azeredo TR. Diagnostic support system for the detection of microcalcifications in digital mammograms. In XXXII Encontro Nacional de Engenharia de Produção. Desenvolvimento Sustentável e Responsabilidade Social: As Contribuições da Engenharia de Produção; 2012 Out 15-18; Bento Gonçalves: RS. [internet]. Disponível em: http://www.abepro.org.br/biblioteca/enegep2012_TN_STP_162_947_21082.pdf
 24. Alves EDS, Souza Filho, JBO, Galliez RM, Kritski A. Suporte ao isolamento de pacientes suspeitos de tuberculose pulmonar por comitês de redes MLP. In: XXV Congresso Brasileiro de Engenharia Biomédica – CBEB; 2016 Out 17-20: Fóz do Iguaçu: PR.
 25. Hartz ZMA. Avaliação dos programas de saúde: perspectivas teórico metodológicas e políticas institucionais. *Ciênc Saúde Colet.* 1999;4(2):341-53.
 26. Medina MG, Aquino R, Vilasbôas AL, Mota E, Júnior P, Pereira E, Luz LA, Anjos DS, Pinto IC. Promoção da saúde e prevenção de doenças crônicas: o que fazem as equipes de Saúde da Família? *Saúde Debate.* 2014;38 (nº. esp.):69-82.