

Predição de atendimento à “Lei dos 60 dias” dentro do programa de navegação de pacientes com câncer de mama no Rio de Janeiro

Authors: Sandra Gioia^{1,2,4}, Cristiane Torres¹, Renata Galdino¹, Lucia Brigagão¹, Antonio Valadares², Fernando Seol², Sandra San Miguel³, Lindsay Krush^{4,5}, Paul Goss^{4,5}

¹State Secretariat of Health, Rio de Janeiro, Brazil

²Israelita Albert Einstein Hospital, São Paulo, Brazil

³National Cancer Institute, Washington DC, USA

⁴Global Cancer Institute, Boston, Massachusetts, USA

⁵Massachusetts General Hospital, Boston, Massachusetts, USA

Corresponding author: Sandra Marques Silva Gioia, MD; Diagnostic and Image Center, Avenida Presidente Vargas, 1733 - Rio de Janeiro, RJ, 20210-030; sandra.gioia@gmail.com

Keywords: Patient Navigation; Breast neoplasms; Barriers; Health Systems; Machine Learning

ABSTRACT

An applied study was conducted on how the use of machine learning techniques can help in the process of identifying compliance with the "60 Day Law", which states that all patients with cancer within the public system must initiate the treatment within 60 days after the diagnosis of cancer. The AdaBoost learning model identified 38 important attributes to predict initiation of treatment within 60 days with accuracy and f-score of 0.8888 and 0.8333, respectively. The identified attributes simplify the information necessary for breast cancer patient navigation in Rio de Janeiro.

RESUMO

Foi realizado um estudo aplicado sobre como o uso de técnicas de aprendizado de máquina pode ajudar no processo de identificação de atendimento à “Lei dos 60 dias”, em que todos os pacientes com câncer do sistema público devem iniciar o tratamento dentro de 60 dias após o diagnóstico. AdaBoost identificou 38 atributos para prever o início do tratamento no prazo de 60 dias com acurácia e f-score de 0,8888 e 0,8333, respectivamente, simplificando as informações necessárias para a navegação das pacientes com câncer de mama no Rio de Janeiro.

INTRODUÇÃO

Até 2025, estimativas sugerem que 50% dos novos casos e 60% das mortes causadas pelo câncer devam ocorrer nos países em desenvolvimento.⁽¹⁾ Em países como Estados Unidos da América (EUA), Reino Unido, França e Austrália, houve declínio da mortalidade nas últimas duas décadas, enquanto, na América Latina, observou-se o aumento da mortalidade pela doença no mesmo período.⁽²⁾ A sobrevivência em países latino-americanos em geral encontra-se, em média, 20% abaixo daquela em países europeus e nos EUA.⁽²⁾

O câncer de mama representa um grande problema de saúde pública mundial. Em 2016, foi a segunda neoplasia maligna mais incidente, com cerca de 2 milhões de casos novos e uma das principais causas de morte por câncer, com cerca de 626.000 óbitos em todo o mundo.⁽³⁾

No Brasil, o câncer de mama é o mais comum e a principal causa de morte por esta doença entre as mulheres. Em 2015, ocorreram 15.403 óbitos por câncer de mama no país; estimam-se 59.700 novos casos para o ano de 2018.^(4,5) Barreiras ao acesso aos cuidados de câncer no Brasil levam a atrasos de diagnóstico e tratamento, com os consequentes estágios avançados na sua apresentação e uma alta taxa de mortalidade. Em países de média e baixa renda, os longos atrasos para diagnóstico e tratamento frequentemente levam à progressão clínica da doença: nos EUA, 60% dos cânceres de mama são diagnosticados numa fase inicial da doença, enquanto no Brasil isto é verdade para apenas 20% dos diagnósticos.⁽⁶⁾

Reconhecendo o impacto negativo desta situação, em 2012, o governo brasileiro decretou a Lei No. 12.732/12 do Ministério da Saúde, ou a "Lei dos 60 dias". Esta lei estabelece que o tratamento para qualquer tipo de câncer para os pacientes do sistema público de saúde – Sistema Único de Saúde (SUS) - deve começar no prazo de 60 dias a partir do diagnóstico definitivo.⁽⁷⁾ Dados coletados de 239 hospitais em todo o Brasil mostraram que quase 40% das pacientes com câncer de mama não conseguiram iniciar o tratamento dentro do período de 60 dias.⁽⁹⁾ Esta estatística varia muito por região, com o estado do Rio de Janeiro relatando que mais de 70% das mulheres deixam de iniciar o tratamento no prazo dos 60 dias mandatórios.^(8,9)

Neste contexto, o Programa de Navegação de Pacientes (PNP), "um processo coordenado de assistência individualizada e oferecido aos pacientes para superar barreiras no acesso aos cuidados e tratamento oportuno e qualidade em sistemas de saúde complexos", pode potencialmente permitir a aplicação adequada desta Lei Federal.⁽¹⁰⁾ O PNP tem mostrado sucesso entre as populações carentes nos EUA, mas a sua implementação global tem sido limitada. O PNP tem o potencial para aliviar as barreiras do sistema de saúde e apoiar o respeito à "Lei dos 60 dias" no Brasil, que, por sua vez, poderia melhorar os resultados de mulheres com câncer de mama no Rio de Janeiro.⁽¹¹⁾

O campo de estudo interessado no desenvolvimento de algoritmos de computador para transformar dados em ação inteligente é conhecido como aprendizado de máquina. Esse campo teve origem em um ambiente em que os dados disponíveis, métodos estatísticos e o poder tecnológico evoluíram rápida e simultaneamente. O crescimento dos dados exigiu um poder computacional adicional, que, por sua vez, estimulou o desenvolvimento de métodos estatísticos para analisar

grandes conjuntos de dados. Isso criou um ciclo de avanço que permite que dados ainda maiores e mais interessantes sejam coletados.⁽¹²⁾

Os algoritmos de Machine Learning podem ser divididos em dois grupos principais: aprendizado supervisionado, usado para construir modelos preditivos, e aprendizado não supervisionado, usado para construir modelos descritivos. Um modelo preditivo é utilizado para tarefas que envolvem, como o nome indica, a previsão de um valor usando outros valores no conjunto de dados. Neste sentido, o algoritmo de aprendizado tenta descobrir e modelar o relacionamento entre a variável dependente (variável target ou variável resposta, que está sendo prevista) e as demais variáveis independentes.⁽¹²⁾

Este estudo tem como objetivo identificar as principais variáveis que predizem se um paciente iniciará o tratamento dentro do prazo estabelecido por lei.

MATERIAL E MÉTODOS

Local do estudo e fonte de dados

As pacientes foram recrutadas para receber a intervenção no Centro Estadual de Diagnóstico e Imagem, conhecido como Rio Imagem. Neste Centro Diagnóstico são realizadas aproximadamente 4.000 mamografias por mês de mulheres provenientes dos 92 municípios do estado do Rio de Janeiro e usuárias do SUS.

No caso das biópsias realizadas no Rio Imagem, todos os fragmentos são enviados para o laboratório da Secretaria Estadual de Saúde, e o resultado é encaminhado diretamente para o Rio Imagem, onde a paciente o receberá num prazo de até 20 dias na recepção de laudos. Porém não há nenhuma supervisão para saber se a paciente conseguirá ser encaminhada para tratamento em local especializado. Ou seja, a paciente é responsável por buscar o centro apropriado para o início do tratamento, usando a rede existente de centros de tratamento. A introdução do PNP pode ser uma alternativa para esta lacuna no cuidado da paciente com câncer de mama.

Métricas do estudo

As métricas coletadas foram divididas em duas partes:

1. Questionários principais - Coleta de informações sociodemográficas e gerais sobre as características da neoplasia da paciente. Estes questionários foram desenhados para este estudo.
2. Entrevista Psicossocial - Coleta de informações mais detalhadas sobre a doença da paciente e suas lutas. São questionários padronizados para medir diferentes aspectos do tratamento do câncer.

Análise estatística

Para o desenvolvimento da análise, foram executadas as seguintes etapas:

- Seleção, obtenção e exploração dos dados.
- Pré-processamento das bases de dados:

- Antes que os dados pudessem ser utilizados como input para os algoritmos de aprendizado, foram realizadas uma avaliação de necessidade de tratamento, formatação e reestruturação das bases de dados.
- Também foi avaliada a necessidade de transformação dos principais desvios das variáveis com dados contínuos, caso registros do mesmo atributo contenham valores discrepantes.
- Outra transformação requerida foi a normalização de escala atributos numéricos, para garantir que cada atributo fosse tratado com o mesmo peso durante a aplicação de aprendizado supervisionado.
- Transformação de dados categóricos em numéricos: Algoritmos de aprendizado recebem inputs numéricos, o que requer que os atributos categóricos (sexo, escolaridade etc.) sejam convertidos.
- Embaralhamento e divisão dos dados em conjuntos de treinamento e teste por meio de metodologia de validação cruzada.
- Avaliação da performance do modelo:
 - Testes de 3 algoritmos de aprendizado supervisionado e naive predictor.
 - Análise de acurácia, precisão, sensibilidade e F1 score.
- Criação do processo de treinamento e predição:
 - Avaliação de performance dos modelos escolhidos, de forma a treinar modelos utilizando vários tamanhos de conjuntos de dados para treinamento, além de efetuar predições nos dados de teste. Assim, será possível calcular o tempo total de predição, bem como a acurácia e o F-score para os dois conjuntos de dados (treinamento e testes).
 - Validação inicial do modelo, com diferentes tamanhos de conjuntos de dados de treinamento (p. ex.: 1%, 10% e 100% dos dados)
 - Escolha do melhor modelo de aprendizado supervisionado para utilizar nos dados de testes.
 - Validação final do modelo: Refinamento do modelo escolhido, de forma a obter resultados melhores, e comparação entre os resultados dos modelos otimizado e não otimizado.
 - Avaliação de relevância de atributos, de forma a determinar quais variáveis possuem maior poder de predição. Assim, com menos atributos para treinar, espera-se que o treinamento e a predição tenham um tempo reduzido de execução e, conseqüentemente, menor custo.

RESULTADOS

No período de agosto de 2017 a maio de 2018, 105 pacientes com idade entre 33-80 anos (média de 59 anos) foram recrutadas para o PNP. Oito pacientes foram excluídas por perda de seguimento. Todos os pacientes eram do sexo feminino, usuárias do SUS, moravam em área urbana e falavam apenas português. Entre as 98 pacientes incluídas para análise, vinte e três por cento (23%) delas tinham abaixo de 50 anos. As pacientes apresentaram estadiamento 0-I (17%), II-III (78%) e IV (5%). Houve duas mortes relacionadas ao câncer de mama nesse grupo. O PNP teve 100% de satisfação das pacientes e em 52% dos casos ajudou as pacientes a iniciar o tratamento dentro do prazo estabelecido por lei. Todas as pacientes tiveram barreiras, de 2 a 12 barreiras (em média 5). As principais barreiras para o cumprimento da Lei

foram: Medo e pensamentos fatalistas (99%), problemas financeiros (79%), cuidados de saúde descoordenados (76%), profissionais de saúde ignoram a Lei dos 60 dias (75%), necessidade de refazer exames de estadiamento (52%), preocupação com a comunicação com a equipe médica (52%), transporte (42%), dificuldade de obter consulta de risco cirúrgico (12%), filas para tratamento cirúrgico (12%) e dificuldade de inserção no sistema de regulação na atenção básica (11%).

Para as análises estatísticas foram utilizados os questionários comuns ou principais e psicossocial basal. Foram realizados: seleção, obtenção e exploração dos dados e pré-processamento das bases de dados:

- Normalização de escala de atributos numéricos para garantir que cada atributo fosse tratado com o mesmo peso durante a aplicação de aprendizado supervisionado.
- Conversão de variáveis categóricas por meio da estratégia "one-hot encoding" - Transformação de dados categóricos em numéricos: Algoritmos de aprendizado recebem inputs numéricos, o que requer que os atributos categóricos (sexo, escolaridade etc.) sejam convertidos. Nesse sentido, as 219 variáveis restantes do processo de transformação foram convertidas em 902 variáveis após aplicação de metodologia *one-hot encoding*.
- Embaralhamento e divisão dos dados em conjuntos de treinamento e teste por meio de metodologia de validação cruzada: Com todas as variáveis de categoria como atributos numéricos e todos os atributos numéricos normalizados, foi feita a divisão dos dados em conjuntos de treinamento e de teste [em função da pequena quantidade de observações (98 observações), foi usada a técnica de crossvalidation para extração dos dados de treinamento e teste].

Implementação

Nesta etapa, foi feita a avaliação da performance do modelo, contemplando as seguintes etapas:

- Testes de 3 algoritmos de aprendizado supervisionado e naive predictor.
- Análise de acurácia, precisão, sensibilidade e F1 score.

Métricas utilizadas:

- Accuracy mede com que frequência o classificador faz a predição correta. É a proporção entre o número de predições corretas e o número total de predições (o número de registros testados).

- Precision informa qual a proporção entre:

[Verdadeiros positivos/(Verdadeiros positivos + Falso positivos)]

- Recall (sensibilidade) nos informa qual a proporção entre:

[Verdadeiros positivos/(Verdadeiros positivos + Falso negativos)]

- F1 score é calculado através da média (harmônica) dos valores de precision e de recall. Este score pode variar entre 0 e 1, sendo 1 o melhor resultado possível para o F1 score (consideramos a média harmônica, pois estamos lidando com proporções).

Usar a acurácia como uma métrica para avaliar a performance de um modelo é um parâmetro adequado. Assim, a habilidade do modelo em predizer com precisão aqueles que atendem à Lei dos 60 dias é mais importante do que realizar o recall destes indivíduos. Também será utilizada a fórmula F-beta score como uma métrica que considera ambos: precision e recall.

Para o Naive Predictor, foram calculados os seguintes parâmetros: Naive Predictor: [Accuracy score: 0. 4796, F-score: 0. 5353].

Após essa etapa, foram criados os processos de treinamento e predição, com o objetivo de avaliar a performance dos modelos escolhidos, de forma a treinar modelos utilizando vários tamanhos de conjuntos de dados para treinamento, além de efetuar predições nos dados de teste. Assim, foi possível calcular o tempo total de predição, assim como a acurácia e o F-score para os dois conjuntos de dados (treinamento e testes).

Foram gerados os seguintes outputs: Modelo – Classes: Atende Lei 60 dias: Sim=1 / Não = 0)

Com base nos 3 modelos analisados, o modelo de aprendizado AdaBoost teve resultados superiores aos demais algoritmos testados (Decision Tree e GaussianNB), com relação à acurácia e f-score nos resultados de testes. Além disso, teve bom desempenho com relação aos tempos de predição, fazendo deste modelo um candidato adequado para o refinamento (Figura 1).




Figura 1. Matrizes de confusão conforme os modelos de aprendizado utilizados

Validação final do modelo:

Nesta etapa, foram realizados o refinamento do modelo escolhido, de forma a obter resultados melhores, e a comparação entre os resultados do modelo otimizado e o não otimizado. Foi realizado o GridSearch para otimização em todo o conjunto de dados de treino ('X_train' e 'y_train') por meio do tuning de pelo menos um parâmetro, com o objetivo de verificar se é possível melhorar os parâmetros anteriormente encontrados, conforme indicado na Figura 2:

```

Modelo não otimizado
-----
Score accuracy nos dados de teste: 0.7778
F-score nos dados de teste: 0.7500
train+pred tempo: 0.01 segs

Modelo Otimizado
-----
Score final accuracy nos dados de teste: 0.8889
F-score final nos dados de teste: 0.8333
train+pred tempo: 27.41 seg
AdaBoostClassifier(algorithm='SAMME.R',
                   base_estimator=DecisionTreeClassifier(class_weight=None, criterion='gini', max_depth=1,
                                                         max_features=None, max_leaf_nodes=None,
                                                         min_impurity_decrease=0.0, min_impurity_split=None,
                                                         min_samples_leaf=1, min_samples_split=2,
                                                         min_weight_fraction_leaf=0.0, presort=False, random_state=None,
                                                         splitter='best'),

```

Figura 2. Comparação dos modelos não otimizado e otimizado utilizando o GridSearch

Avaliação de relevância de atributos

Na etapa de avaliação de relevância de atributos, o objetivo foi de determinar quais variáveis possuem maior poder de predição. Assim, com menos atributos para treinar, espera-se que o treinamento e a predição tenham um tempo reduzido de execução e, conseqüentemente, menor custo.

Neste sentido, foram identificados 38 (trinta e oito) atributos que contribuem com 95% da importância de todos os atributos presentes nos dados (de um total de 902 atributos avaliados, após consolidação e tratamento de todas as bases analisada), indicando que pode ser feitas uma redução dos atributos e simplificação da informação requerida para o aprendizado pelo modelo.

Assim, para modelagem dos fatores que influenciam o cumprimento da Lei dos 60 dias, os atributos estão ordenados na Tabela 1.

Tabela 1. Fatores que influenciam o cumprimento da Lei dos 60 dias

Contribuição Individual	Contribuição Acumulada	Variável Combinada (Questionário+Questão+Resposta)		
		Questionário	Questão	Resposta
6,00%	6,00%	Formulário 3_Datas Clínicas	Estadiamento clínico TNM	IIIB
6,00%	12,00%	Barreiras	Problemas do sistema com a programação do seu cuidado de saúde	-
4,00%	16,00%	Formulário 1_Questionário de Inscrição	12. O custeio das pessoas que moram com você depende unicamente de sua renda pessoal?	Não
4,00%	20,00%	EP Parte 8_ FACT-B (Câncer de mama)	5. Sinto-me incomodada com a queda do cabelo	2 (Mais ou menos)
4,00%	24,00%	EP Parte 7_ FACT-G	7. Estou satisfeita com a minha vida sexual	3 (Muito)
4,00%	28,00%	EP Parte 7_ FACT-G	4. Aceito a minha doença	1 (Um pouco)
4,00%	32,00%	EP Parte 7_ FACT-G	1. Estou sem energia	0 (Nem um pouco)
4,00%	36,00%	Barreiras	Necessidade de refazer exames	-
2,00%	38,00%	Formulário 3_Datas Clínicas (Responses)	Receptor Progesterona	sem informações
2,00%	40,00%	Formulário 3_Datas Clínicas (Responses)	Qual o centro de referência?	Hospital Darcy Vargas
2,00%	42,00%	Formulário 3_Datas Clínicas (Responses)	Ki67	sem informações
2,00%	44,00%	Formulário 3_Datas Clínicas (Responses)	HER2	negativo
2,00%	46,00%	Formulário 3_Datas Clínicas (Responses)	Estadiamento clínico TNM	IV
2,00%	48,00%	Formulário 1_Questionário de Inscrição	IDADE	-
2,00%	50,00%	formulário 1_Questionário de Inscrição	3. Quanto tempo o paciente leva para chegar à clínica (Rio Imagem) de sua casa por seu modo usual de transporte?	<1 hora
2,00%	52,00%	Formulário 1_Questionário de Inscrição	10. Como muitas pessoas vivem com você em sua casa?	-

2,00%	54,00%	EP Parte 11_ Auto-eficácia	7. Discutir abertamente com seu médico sobre aspectos pessoais que estejam relacionados à sua doença	3 (Bastante)
2,00%	56,00%	EP Parte 11_ Auto-eficácia	6. Perguntar ao seu médico sobre aspectos da sua doença que a preocupam	3 (Bastante)
2,00%	58,00%	EP Parte 11_ Auto-eficácia	21. Impedir que a fadiga o impeça de fazer as coisas que você tem interesse em fazer	4 (Totalmente confiante)
2,00%	60,00%	EP Parte 11_ Auto-eficácia	2. Ter ajuda de parentes e amigos para me ajudar em coisas que preciso (como cuidar da casa, fazer comprar, cozinhar, transporte)	4 (Totalmente confiante)
2,00%	62,00%	EP Parte 11_ Auto-eficácia	2. Ter ajuda de parentes e amigos para me ajudar em coisas que preciso (como cuidar da casa, fazer comprar, cozinhar, transporte)	3 (Bastante)
2,00%	64,00%	EP Parte 11_ Auto-eficácia	16. Evitar se sentir sozinho	3 (Bastante)
2,00%	66,00%	EP Parte 8_ FACT-B (Câncer de mama)	9. Consigo sentir-me mulher	0 (Nem um pouco)
2,00%	68,00%	EP Parte 8_ FACT-B (Câncer de mama)	6. Fico preocupada com a possibilidade de que outros membros da minha família um dia tenham a mesma doença que eu	3 (Muito)
2,00%	70,00%	EP Parte 8_ FACT-B (Câncer de mama)	5. Sinto-me incomodada com a queda do cabelo	Não sei
2,00%	72,00%	EP Parte 8_ FACT-B (Câncer de mama)	5. Sinto-me incomodada com a queda do cabelo	4 (Muitíssimo)
2,00%	74,00%	EP Parte 8_ FACT-B (Câncer de mama)	5. Sinto-me incomodada com a queda do cabelo	1 (Um pouco)
2,00%	76,00%	EP Parte 8_ FACT-B (Câncer de mama)	4. Sinto-me sexualmente atraente	1 (Um pouco)
2,00%	78,00%	EP Parte 8_ FACT-B (Câncer de mama)	10. Sinto dores em algumas regiões do meu corpo	2 (Mais ou menos)
2,00%	80,00%	EP Parte 7_ FACT-G	6. Gosto das coisas que normalmente faço para me divertir	3 (Muito)
2,00%	82,00%	EP Parte 7_ FACT-G	5. Durmo bem	1 (Um pouco)
2,00%	84,00%	EP Parte 7_ FACT-G	4. Tenho dores	2 (Mais ou menos)
2,00%	86,00%	EP Parte 7_ FACT-G	4. Aceito a minha doença	0 (Nem um pouco)
2,00%	88,00%	EP Parte 7_ FACT-G	4. A minha família aceita a minha doença	4 (Muitíssimo)
2,00%	90,00%	EP Parte 7_ FACT-G	2. Estou satisfeita com a maneira como enfrento a minha doença	2 (Mais ou menos)
2,00%	92,00%	EP Parte 7_ FACT-G	2. Estou satisfeita com a maneira como enfrento a minha doença	0 (Nem um pouco)

2,00%	94,00%	EP Parte 3_ PEPPI (Eficácia percebida na relação médico paciente)	5. Quão confiante você está na sua capacidade de aproveitar ao máximo a sua visita ao médico?	4
2,00%	96,00%	EP Parte 2_ LES-10 (Questionário de experiência de vida)	2. Impacto nos hábitos de sono / A Este evento ocorreu?	Não (vá direto para a próxima questão)
2,00%	98,00%	Barreiras	Risco Cirúrgico	-
2,00%	100,00%	Barreiras	Inserção no SER	-

DISCUSSÃO

O uso de navegador de pacientes facilita a utilização apropriada e eficiente dos serviços. É uma atividade considerada indicador de qualidade em muitos serviços de saúde nos EUA, Canadá e Europa e ainda pouco estudada em países periféricos. O navegador é um profissional de saúde treinado para ser gestor de caso e serve de elo entre os pacientes e o sistema, profissionais e provedores de saúde, levando equidade para as populações vulneráveis.^(11,13)

O navegador de paciente, profissional de saúde treinado, facilita a tramitação de pacientes no sistema de saúde, ajudando-os a superar as barreiras institucionais, socioeconômicas e pessoais para o acesso. Fornece serviços como agendamento de compromissos de diagnóstico e de acompanhamento, facilitando encaminhamentos do sistema de saúde, e coordena a comunicação entre pacientes e profissionais de saúde. Este profissional ajuda as pacientes a receberem cuidados médicos em tempo hábil e a reduzir os atrasos nos cuidados e taxas de perda de seguimento.⁽¹¹⁾

Apesar de existir no Brasil uma trajetória de ações de prevenção e controle do câncer de mama, o cenário de alta incidência, doença diagnosticada em estágio avançado e alta mortalidade continuam sendo uma constante. Barreiras ao acesso aos cuidados de saúde levam a atrasos de diagnóstico e tratamento, com os conseqüentes estágios avançados na apresentação e uma alta taxa de mortalidade.⁽¹⁴⁾

Foi realizada a avaliação de relevância de atributos, de forma a determinar quais variáveis possuem maior poder de predição. Assim, com menos atributos para treinar, espera-se que o treinamento e a predição tenham um tempo reduzido de execução e, conseqüentemente, menor custo. Neste sentido, foi identificado que os 38 (trinta e oito) atributos mais importantes contribuem para 95% da importância de todos os atributos presentes nos dados (de um total de 902 atributos avaliados, após consolidação e tratamento de todas as bases analisadas), indicando que pode ser feita uma redução dos atributos e simplificação da informação requerida para o aprendizado pelo modelo. As variáveis categorizadas que facilitaram o cumprimento da lei foram: doença em estadiamento avançado; ajudar proativamente pacientes com barreiras para iniciar o tratamento; pacientes idosos; e apoio social.

CONCLUSÕES

O PNP no Rio de Janeiro gerou uma experiência positiva para as pacientes no sistema público de saúde, sendo um processo intencional e proativo de auxílio individual através do sistema de saúde. O estudo não alcançou a taxa de sucesso de 70% de cumprimento da Lei como pretendida (tendo atingido 52%). No entanto, as barreiras que a PN não consegue superar, como a falta de recursos humanos e

suprimentos médicos, foram informadas às autoridades de saúde e aos administradores hospitalares. Foram identificados 38 atributos importantes, o que simplifica a informação requerida para o aprendizado pelo modelo.

REFERÊNCIAS

1. Bray F, Ren JS, Masuyer E, Ferlay J. Global estimates of cancer prevalence for 27 sites in the adult population in 2008. *Int J Cancer* 2013;132(5):1133-45.
2. Goss PE, Lee BL, Badovinac-Crnjevic T, et al. Planning cancer control in Latin America and the Caribbean. *Lancet Oncol* 2013;14:391-436.
3. Bray F et al. Global Cancer Statistics 2018: GLOBOCAN Estimates of Incidence and Mortality Worldwide for 36 Cancers in 185 Countries. *CA: A Cancer Journal for Clinicians* 2018;0:1-31.
4. Brasil. Instituto Nacional de Câncer. Estatísticas do câncer: Mortalidade. Disponível em: <http://www1.inca.gov.br/vigilância/mortalidade.asp>.
5. Brasil. Instituto Nacional de Câncer. Estimativa 2018: Incidência de câncer no Brasil. Disponível em: <http://www.inca.gov.br/estimativa/2018/sintese-de-resultados-comentarios.asp>.
6. Unger-Saldãna K. Challenges to the early diagnosis and treatment of breast cancer in developing countries. *World J Clin Oncol* 2014;5:465-77.
7. Brasil. Presidência da República. Lei nº. 12.732, de 22 de novembro de 2012. Dispõe sobre o primeiro tratamento de paciente com neoplasia maligna comprovada e estabelece prazo para seu início. *Diário Oficial da União* 2012; 23 nov. Seção I:1.
8. Brasil. Ministério da Saúde. Portaria nº 3.394, de 30 de dezembro de 2013. Institui o Sistema de Informação de Câncer (SICAN) no âmbito do Sistema Único de Saúde (SUS). *Diário Oficial da União* 2013; 31 dez. Seção I:57-8.
9. Federação Brasileira de Instituições Filantrópicas de Apoio a Saúde da Mama. A implementação da Lei dos 60 dias. Disponível em: http://www.femama.org.br/novo/arquivos/audiencia_publica_pesquisa_60_dias.pdf.
10. Bukowski A, Chávarri-Guerra Y, Goss PE. The potential role of patient navigation in low- and middle-income countries for patients with cancer. *JAMA Oncol* 2016;2:994-95.
11. Bukowski A, Gioia S, Chavarri-Guerra Y, Soto-Perez-de-Celis E, St. Louis J, Paulino E, et al. Patient Navigation to Improve Access to Breast Cancer Care in Brazil. *J Global Oncology* 2016;1-5.
12. Lantz B. *Machine Learning with R*. Birmingham: Packt Publishing; 2014.
13. Harford J, Azavedo E, Fischietto M. Guideline Implementation for Breast Healthcare in Low- and Middle-Income Countries. *CANCER Supplement* 2008;15(113):2282-96.
14. Gioia S. Why is breast cancer early detection important? *Mastology* 2017; 27(3):173-5.
15. Naomi Ko et al. Can Patient Navigation Improve Receipt of Recommended Breast Cancer Care? Evidence from the National Patient Navigation Research Program. *J Clin Oncol* 2014;32:2758-64.