



Recebido: 23 set. 2019 - Aprovado: 08 mar. 2020

UM LEVANTAMENTO SOBRE O USO DE ALGORITMOS DE APRENDIZADO DE MÁQUINA EM AUDITORIAS DE PLANOS DE SAÚDE

A SURVEY ON MACHINE LEARNING ALGORITHM USAGE IN THE AUDIT OF HEALTH PLANS



Jean Carlo Raduenz

Bacharel em Ciência da Computação – UNIVALI – Universidade do Vale do Itajaí
São José – Santa Catarina – Brasil
jeanraduenz@yahoo.com.br



Anita Maria da Rocha Fernandes

Doutora em Engenharia de Produção – UNIVALI – Universidade do Vale do Itajaí
São José – Santa Catarina – Brasil
anita.fernandes@univali.br

Resumo: apesar das operadoras de saúde terem mais de 47 milhões de clientes com plano de saúde no Brasil, estas companhias ainda possuem processos que são manuais. Um destes processos é o de auditoria médica que realiza a análise de cada conta com despesas que foram realizadas pelo beneficiário da operadora em algum hospital, clínica ou laboratório. Cada conta é analisada com o objetivo de verificar se não existe algo fora do contexto de uma cirurgia, exame ou consulta. Os custos destas auditorias são elevados e o resultado é variado e de acordo com o conhecimento individual do auditor. Além de ser um processo demorado, estas contas somente serão pagas para quem prestou o serviço após a análise dos auditores, trazendo insatisfação para quem aguarda o pagamento. A execução manual deste processo está suscetível a falhas e fraudes. Neste contexto, os algoritmos de Aprendizado de Máquina são utilizados para auxiliar no processo de auditoria em várias áreas do conhecimento. Sendo assim, este artigo .

Palavras-Chave: Planos de Saúde. Auditoria. Aprendizado de Máquina.

Abstract: Although health care providers have more than 47 million health insurance clients in Brazil, these companies still have processes that are manual. One of these processes is that of the medical audit that performs the analysis of each account with expenses that were incurred by the operator's beneficiary in any hospital, clinic or laboratory. Each account is reviewed to make sure that there is nothing outside the context of a surgery, examination or consultation. The costs of these audits are high and the outcome is varied and according to the auditor's individual knowledge. In addition to being a lengthy process, these bills will only be paid to those who provided the service after the auditors' review which brings dissatisfaction to those awaiting payment. Manual execution of this process is susceptible to failure and fraud. In this context, Machine Learning algorithms are used to assist in the audit process in various areas of knowledge. Thus, this paper presents a survey on the application of Machine Learning algorithms in medical audits, analyzing which algorithms are most used.

Keywords: Health Insurance. Audit. Machine Learning.

Cite como:

American Psychological Association (APA)

Raduenz, J. C., & Fernandes, A. M. R. (2020). Um levantamento sobre o uso de algoritmos de aprendizado de máquina em auditorias de planos de saúde. *Rev. gest. sist. saúde*, São Paulo, 9(1), 119-131 <https://doi.org/10.5585/rgss.v9i1.15296>.





1 Introdução

O mercado de saúde suplementar cresce a cada ano e em maio de 2019 atingiu a marca de 47 milhões de pessoas que possuem algum plano de saúde no Brasil (Instituto de Estudos de Saúde Suplementar [IESS], 2019). Segundo a Agência Nacional de Saúde Suplementar [ANS], este segmento gerou aproximadamente R\$ 160 bilhões em custos assistenciais (gastos com internações, tratamentos, consultas e terapias) em 2018 pelos clientes das operadoras de planos de saúde (ANS, 2019).

O volume de internações e de outros procedimentos aumenta a cada ano, segundo Minami (2018). Consequentemente, o volume de dados para ser analisado cresce proporcionalmente ao número de atendimentos. Entre os anos de 2017 e 2018 houve um aumento de 5,4% de atendimentos que geraram ainda mais dados a serem analisados (Minami, 2018). Para atender a seus clientes, as operadoras compram serviços de médicos e prestadores (responsáveis pelo atendimento aos beneficiários da operadora), formando a rede prestadora de serviços.

Quando um cliente utiliza esta rede, uma conta médica é gerada para o pagamento pelo serviço prestado. Esta conta passa por várias etapas, dentre elas a de auditoria médica realizada pelo auditor (médico ou enfermeiro). A atividade do auditor médico é regulamentada pelo Conselho Federal de Medicina na Resolução nº 1.614/2001 (Brasil, 1998) e a do auditor enfermeiro pelo Conselho Federal de Enfermagem na Resolução nº 266/2001.

As operadoras necessitam de uma equipe de auditores para analisar se a utilização feita na rede prestadora está de acordo com a cobertura do plano contratado com o prestador e com as boas práticas médicas, evitando, assim, fraudes, abuso de exames ou qualquer outra má fé por parte do médico, prestador ou até mesmo do usuário do plano (Brasil, 1998). Vale ressaltar que o auditor nunca interfere no trabalho do médico. Seu dever é apenas emitir um relatório sobre a adequação dos procedimentos e, se for o caso, denunciar condutas erradas ou antiéticas. O resultado da auditoria depende da interpretação do auditor, ou seja, do conhecimento que o profissional possui sobre o assunto que está sendo analisado.

Quando, após análise, uma conta médica sofre alguma alteração, seja de valor ou de quantidade, esta alteração é caracterizada como glosa (Silva, Hinrichsen, Brayner, Vilella & Lemos, 2017). Se a conta médica apresentar alguma glosa na auditoria, o pagamento ao prestador será realizado de acordo com o parecer do auditor. A ANS (continuar aqui)

A ANS determina uma lista de possíveis glosas. Todas as contas e glosas são registradas no banco de dados da operadora do plano de saúde, com as devidas análises e considerações.





Para realizar o pagamento das contas médicas aos prestadores, as operadoras de planos de saúde utilizam regras para as solicitações de serviços do plano de saúde (consultas, exames, internações) e outras para os pagamentos aos prestadores de serviço. Cada prestador pode ter regras específicas em contrato, o que exige conhecimento especializado dos auditores para cada conta médica analisada.

Os pagamentos aos prestadores podem ser realizados em sua totalidade, glosados parcialmente ou glosados totalmente. A Tabela 1 mostra alguns exemplos de regras, nas quais a análise da ocorrência simultânea das duas condições gera um resultado.

Tabela 1 - Exemplos de regras de análise

Condição 1	Condição 2	Resultado
Sexo Masculino	Parto Cesariana	Negado
Sexo Feminino	Vasectomia	Negado
Cirurgia	Procedimento secundário (via de acesso 2)	Paga 50% do valor
> 18 anos	Consulta Puericultura	Negado
Beneficiário ativo	Consulta Eletiva	Paga 100%

Fonte: Os próprios autores, ano 2019.

Cada país pode usar um ou mais modelos de pagamento, conforme sua estrutura de saúde suplementar. Alguns exemplos de modelos são: DRG (*Diagnosis Related Groups*), ABP (*Adjustable Budget Payment*), GB (*Global Budget*), *Shared Savings Programs*, *Capitation* e FFS (*Fee for Service*). No Brasil, utiliza-se o GB e o FFS, porém o mais aplicado é o *Fee for Service*, que favorece o consumo de exames e consultas. Este modelo, que privilegia a quantidade de atendimentos e não a qualidade, incentiva a maior utilização de procedimentos e insumos, gerando mais desperdício em toda a cadeia (Instituto de Estudos de Saúde Suplementar [IESS], 2013).

Alguns dos principais pontos que corroboram com a ineficiência do modelo *Fee for Service* são:

- Repetição de exames sem necessidade devido à falta de integração dos dados entre operadoras, hospitais, laboratórios e prontuários em geral. Segundo o Instituto de Estudos de Saúde Suplementar [IESS] (2018), em 2017 aproximadamente 19,1% dos gastos assistenciais da saúde suplementar no país foram consumidos por desperdícios e fraudes.
- Exames desnecessários gerados por consultas realizadas com um médico que não é necessariamente o da especialidade que o paciente necessita. Nestas consultas, os



exames são solicitados para atender às expectativas do paciente e para dar um encaminhamento com algum embasamento a outro médico.

- Necessidade de constante rotina de atualização dos auditores sobre novos exames, medicamentos e procedimentos. Esta atualização, por vezes, depende da iniciativa do próprio auditor e fica individualizada, gerando conhecimento distinto nas interpretações das contas médicas.
- Alto custo da equipe de auditoria.

A operadora se beneficia ao ter todas as informações de um cliente porque ela é a fonte pagadora para os prestadores que executam os serviços. Quando um cliente realiza uma consulta, depois faz exames laboratoriais seguidos de exames de imagem, na maioria das vezes estes três procedimentos são realizados em prestadores diferentes. Todas as informações (referentes aos três procedimentos) são destinadas para a operadora com objetivo de realizar o pagamento aos prestadores.

Com a disponibilidade de todos estes dados centralizados na operadora, é possível, com o uso do Aprendizado de Máquina, aumentar a eficiência dos processos de auditoria, seja por tempo de resposta, padrão de informações ou nível de conhecimento. Aprendizagem de Máquina refere-se ao funcionamento de sistemas computacionais capazes de aprender e modificar o seu comportamento em resposta a estímulos externos, ou através de experiências acumuladas durante sua operação (Alpaydin, 2016). Segundo Alpaydin (2016), Aprendizado de Máquina consiste em examinar e experimentar as estratégias mais eficazes para a construção de programas que aprendem a partir da experiência adquirindo conhecimento de forma automática. Várias áreas já utilizam aprendizagem na detecção de fraudes na distribuição de energia (Silva & Scarpel, 2007). Áreas relacionadas a cartão de crédito (Bauder & Khoshgoftaar, 2017) e seguro de vida (Bauder, da Rosa & Khoshgoftaar, 2018) também utilizam Aprendizado de Máquina para detecção de fraudes. A flexibilidade dos métodos de Aprendizado de Máquina os torna mais apropriados para situações nas quais existe pouco conhecimento *a priori* sobre o domínio, e/ou esse conhecimento *a priori* é de difícil elicitação (Mueller & Massaron, 2018).

O Aprendizado de Máquina pode ser classificado em quatro categorias

- i) aprendizagem supervisionada;
- ii) aprendizagem não supervisionada;
- iii) aprendizagem semi supervisioanda; e
- iv) aprendizagem por reforço (Silveira & Bullock, 2017).





Segundo Russel e Norvig (2013), aprendizagem supervisionada é aquela na qual, dado um conjunto de observações ou exemplos rotulados, isto é, conjunto de observações em que a classe, denominada também de atributo meta, de cada exemplo, é conhecida ; o objetivo é encontrar uma hipótese capaz de classificar novas observações entre as classes já existentes.

Ainda, segundo Russel e Norvig (2013), a aprendizagem não supervisionada é aquela na qual, dado um conjunto de observações ou exemplos não rotulados, o objetivo é tentar estabelecer a existência de grupos ou similaridades nesses exemplos. No que tange à aprendizagem semi supervisionada, os autores colocam que a mesma ocorre quando, dado um pequeno conjunto de observações ou exemplos não rotulados e um conjunto de observações e exemplos rotulados, o objetivo é utilizar ambos os conjuntos para encontrar uma hipótese capaz de classificar novas observações entre classes já existentes.

Por fim, Russel e Norvig (2013) apresentam que a aprendizagem por reforço é aquela na qual o agente aprendiz interage com o meio ambiente que o cerca e aprende uma política ótima de ação por experimentação direta com o meio. Dependendo de suas ações, o aprendiz é recompensado ou penalizado. O objetivo do aprendiz é desenvolver uma política ótima que maximize a quantidade de recompensa recebida ao longo da sua execução.

Os tipos de aprendizagem mais utilizados, de maneira geral, nas mais variadas áreas do conhecimento, são a aprendizagem supervisionada e a aprendizagem não supervisionada. Os principais algoritmos de aprendizagem supervisionada são: regressão linear, regressão logística, redes neurais artificiais, SVM (*Support Vector Machine*), *k-nearest neighbor*, e Naive Bayes. No caso da aprendizagem não supervisionada, os principais algoritmos são: redes neurais artificiais, *Expectation-Maximization*, *k-means*, SVM, clusterização hierárquica, análise dos componentes principais e Mapas de Kohonen (Theobald, 2017).

Dentro deste contexto, este trabalho apresenta um levantamento feito em algumas bases de dados com o objetivo de investigar trabalhos que utilizam Aprendizado de Máquina no contexto da auditoria médica.

Este artigo está dividido da seguinte forma: na seção 2 é apresentado o levantamento feito em algumas bases. Na seção 3 são apresentadas as pesquisas selecionadas, de acordo com os critérios adotados, com o objetivo de descrever quais técnicas estão sendo utilizadas e os resultados alcançados. Na seção 4 tem-se as considerações finais da pesquisa. Em seguida, são apresentadas as referências bibliográficas utilizadas.



2 Levantamento dos trabalhos que utilizam aprendizado de máquina no contexto da auditoria médica

O propósito desta revisão sistemática foi investigar a aplicação de Algoritmos de Aprendizado de Máquina (em inglês *Machine Learning*) em processos de auditoria de contas médicas. Para isto, foi feito um levantamento em algumas bases e avaliados os artigos que foram retornados, considerando critérios de inclusão e exclusão pré-estabelecidos. A seguir, o processo de revisão será detalhado.

Para iniciar o processo de revisão, foi necessário estabelecer os objetivos da busca foram estabelecidos três objetivos norteadores:

- como se caracterizam as soluções baseadas em Aprendizado de Máquina para auditoria na área médica (encontrar outliers, fraudes, exames desnecessários, etc.);
- quais algoritmos foram utilizados;
- qual o resultado alcançado (acurácia).

Com base nestes objetivos, iniciou-se a pesquisa estabelecendo as strings de busca para serem utilizadas nas bases IEEE Explore, ACM Digital Library e Science Direct. Para contemplar as peculiaridades de cada uma das bases, foi estabelecido um conjunto específico de strings, conforme apresentado a seguir.

Considerando a base IEEE, a primeira pesquisa realizada com as palavras chaves, retornou uma lista de 894 artigos, utilizado a string ((*"medical"* AND *"health"*) AND (*"audit"* OR *"account"* OR *"payment"* OR *"fraud"*)).

Após análise dos títulos dos artigos, foram excluídos aqueles cujo foco era processamento de imagem, IoT e smartphones, resultado assim em 775 artigos. Após análise dos resultados, foi acrescentada a string de busca da condição de que todos os artigos deveriam possuir os temas de *Artificial Intelligence* ou *Machine Learning* no seu resumo, resultando uma lista de 92 artigos.

Para a base da ACM Digital Library, foi utilizada a string (*+medical +audit +account machine learning artificial intelligence -password -CRUD*), retornando nove artigos para análise.

Na pesquisa na base de dados Science Direct, foram preenchidos dois campos de pesquisa. O primeiro campo, *Find articles with these terms* foi preenchido usando a expressão: *medical audit payment*. O segundo campo *Title, abstract or author-specified keywords* foi preenchido com as palavras: *machine learning artificial intelligence*. A partir desta busca, o sistema retornou sete artigos para análise.





Após a busca nas bases de dados, 107 estudos potenciais foram obtidos. Estes foram analisados para que sua relevância para a pesquisa fosse confirmada e trabalhos não relacionados fossem descartados. Esta seleção foi realizada com base em critérios de inclusão e exclusão, definidos a seguir.

Os critérios de inclusão considerados foram: estudos em inglês ou português; estudos publicados entre os anos de 2014 até maio de 2019; estudos completos que estejam em formato eletrônico; o título do estudo ou o resumo deve conter pelo menos uma das palavras chave; estudos provenientes de conferências, congressos, jornais (fator que auxilia na escolha de artigos de qualidade, pois já passaram por algum tipo de correção por especialistas).

A exclusão de um estudo ocorreu quando este atendeu um dos critérios relacionados a seguir: estudos incompletos; estudos duplicados nas diferentes bases de dados (neste caso foi escolhido o com publicação mais recente e completo); estudo escrito em idioma diferente de inglês ou português; estudos publicados fora do período de 2014 a maio de 2019; e estudos que não respondessem a nenhuma pergunta de pesquisa.

Após a aplicação dos critérios de inclusão e exclusão, restaram nove trabalhos, todos oriundos da IEEE, conforme apresentado na Tabela 2. A coluna “Foco do Trabalho” refere-se ao tipo de auditoria que o trabalho aborda (Autorização, se a auditoria é realizada no momento da autorização, ou Conta Médica, se a auditoria é realizada na conta médica). Já a coluna “Ano”, refere-se ao ano de publicação do trabalho.

**Tabela 2** - Foco e ano de publicação dos trabalhos selecionados

Título	Foco do Trabalho	Ano
A Probabilistic Programming Approach for Outlier Detection in Healthcare Claims (Bauder & Khoshgoftaar, 2016)	Conta Médica	2016
Investigating the Effects of Class Imbalance in Learning the Claim Authorization Process in the Brazilian Health Care Market (Cassimiro, Santana, Santos Neto & Rabelo, 2017)	Autorização	2017
Identifying Frauds and Anomalies in Medicare-B Dataset (Seo & Medelevitich, 2017)	Conta Médica	2017
A Medical Price Prediction System using Hierarchical Decision Trees (Tike & Tavarageri (2017)	Conta Médica	2018
Medicare Fraud Detection using Machine Learning Methods (Bauder & Khoshgoftaar, 2017)	Conta Médica	2018
Medicare Fraud Detection using Random Forest with Class Imbalanced Big Data (Bauder & Khoshgoftaar, 2018)	Conta Médica	2018
Identifying Medicare Provider Fraud with Unsupervised Machine Learning (Bauder, da Rosa & Khoshgoftaar, 2018)	Conta Médica	2017
An Efficient Fraud Identification Method Combining Manifold Learning and Outliers Detection in Mobile Healthcare Services (Gao et al., 2018)	Conta Médica	2018
Patient Cluster Divergence Based Healthcare Insurance Fraudster Detection (Sun et al., 2018)	Conta Médica	2019

Fonte: Os próprios autores, ano 2019.

Na próxima seção, os resultados obtidos serão apresentados e discutidos.

3 Resultados e discussão

Considerando os artigos selecionados, verificou-se que o setor de planos de saúde vem se preocupando com a detecção de fraudes, principalmente nos Estados Unidos, onde a base da Medicare tem sido objeto de várias análises em diversos aspectos, tais como: detecção de médicos e fornecedores que praticam fraudes; detecção de fraude na lista de indivíduos atendidos; detecção de pagamentos a procedimentos que não ocorreram; e detecção de cobranças abusivas e/ou indevidas dos procedimentos médicos. Além dos Estados Unidos, verificou-se que a China também vem desenvolvendo pesquisas para detectar fraudes nas contas médicas. No que tange ao Brasil, verificou-se que as empresas de seguros de saúde têm investido no uso de mineração de dados e técnicas de Aprendizado de Máquina para detectar padrões fraudulentos suspeitos.

A seguir serão apresentados alguns resultados compilados dos artigos, os quais apontam as tendências de utilização de algoritmos de Aprendizado de Máquina na auditoria em planos de saúde.

Considerando os nove trabalhos, verifica-se que 66,67% (6) dos artigos utiliza uma base de dados de origem Americana disponibilizada pelo Medicare. Dois artigos (22,22%) utilizaram





bases de dados chinesas e um artigo (11,11%) utiliza uma base de dados brasileira. No que se refere aos algoritmos utilizados, a Tabela 3 apresenta quais foram aplicados em cada pesquisa.

Tabela 3 - Algoritmos de Aprendizado de Máquina utilizados nos trabalhos selecionados

Título	Algoritmos utilizados	Fonte de Dados
A Probabilistic Programming Approach for Outlier Detection in Healthcare Claims (Bauder & Khoshgoftaar, 2016)	<i>Bayesian Model</i>	Medicare
Investigating the Effects of Class Imbalance in Learning the Claim Authorization Process in the Brazilian Health Care Market (Cassimiro et al., 2017)	<i>Random Forest, SVM, C4.5 e RIPPER</i>	Bases de dados de planos de saúde do Piauí e Pernambuco
Identifying Frauds and Anomalies in Medicare-B Dataset (Seo & Medeleitch, 2017)	<i>PageRank</i>	Medicare
A Medical Price Prediction System using Hierarchical Decision Trees (Tike & Tavarageri (2017)	<i>Random Forest</i>	Medicare
Medicare Fraud Detection using Machine Learning Methods (Bauder & Khoshgoftaar, 2017)	<i>Gradient Boosted Machine, Random Forest, Deep Neural Network, Naive Bayes, Autoencoder, Mahalanobis Distance, k-Nearest Neighbors, Local Outlier Factor e Artificial Neural Network</i>	Medicare
Medicare Fraud Detection using Random Forest with Class Imbalanced Big Data (Bauder & Khoshgoftaar, 2018)	<i>Random Forest</i>	Medicare
Identifying Medicare Provider Fraud with Unsupervised Machine Learning (Bauder, Rosa & Khoshgoftaar, 2018)	<i>Isolation Forest, Unsupervised Random Forest, Local Outliers, Autoencoder e k means</i>	Medicare
An Efficient Fraud Identification Method Combining Manifold Learning and Outliers Detection in Mobile Healthcare Services (Gao et al., 2018)	<i>Simple Local Outlier Factor</i>	China
Patient Cluster Divergence Based Healthcare Insurance Fraudster Detection (Sun et al., 2019)	<i>Patient Cluster Divergence based healthcare insurance fraudster detection method (PCDHIFD)</i>	China

Fonte: os próprios autores, ano 2019.

Conforme apresentado na Tabela 3, o algoritmo *Random Forest* foi o mais aplicado nos trabalhos compilados pela pesquisa.

A Tabela 4 apresenta os algoritmos que obtiveram maior acurácia em cada um dos artigos selecionados, bem como o percentual de acurácia obtido.

**Tabela 4** - Algoritmos que obtiveram maior acurácia

Título	Algoritmo	Acurácia
A Probabilistic Programming Approach for Outlier Detection in Healthcare Claims (Bauder & Khoshgoftaar, 2016)	<i>Bayesian</i>	10%
Investigating the Effects of Class Imbalance in Learning the Claim Authorization Process in the Brazilian Health Care Market (Cassimiro et al., 2017)	<i>Random Forest</i>	74%
Identifying Frauds and Anomalies in Medicare-B Dataset (Seo & Medeleitch, 2017)	<i>PageRank</i>	60% a 80%
A Medical Price Prediction System using Hierarchical Decision Trees (Tike e Tavarageri (2017)	<i>Random Forest</i>	Não apresentou o percentual
Medicare Fraud Detection using Machine Learning Methods (Bauder & Khoshgoftaar, 2017)	<i>Deep Neural Network</i>	80% a 90%
Medicare Fraud Detection using Random Forest with Class Imbalanced Big Data (Bauder & Khoshgoftaar, 2018)	<i>Random Forest</i>	87%
Identifying Medicare Provider Fraud with Unsupervised Machine Learning (Bauder, Rosa & Khoshgoftaar, 2018)	<i>Local Outliers</i>	63%
An Efficient Fraud Identification Method Combining Manifold Learning and Outliers Detection in Mobile Healthcare Services (Gao et al., 2018)	<i>Simple Local Outlier Factor</i>	Não apresentou o percentual
Patient Cluster Divergence Based Healthcare Insurance Fraudster Detection (Sun et al., 2019)	<i>Patient Cluster Divergence based healthcare insurance fraudster detection method (PCDHIFD)</i>	85%

Fonte: os próprios autores, ano 2019.

Após analisar os nove trabalhos selecionados, verificou-se que para o sistema de pagamento utilizado nos Estados Unidos, o algoritmo de *Random Forest* apresenta um desempenho satisfatório. *Random Forest* é um tipo de algoritmo de aprendizagem supervisionada (com uma variável alvo pré-definida), muito utilizado em problemas de classificação. Ele funciona para ambas as variáveis categóricas e contínuas de entrada e de saída. Na árvore de decisão, divide-se a população ou amostra em dois ou mais conjuntos homogêneos (ou sub-populações) com base nos divisores/diferenciadores mais significativos das variáveis de entrada, a partir daí inicia-se o processo de classificação.

Quanto ao trabalho realizado com dados brasileiros, o mesmo referia-se à autorização e não a contas médicas, então, não há indícios, com estes artigos, de qual algoritmo seria apropriado para o sistema de pagamento baseado no *Fee for Service* utilizado no Brasil.

4 Considerações finais

Este trabalho buscou pesquisar trabalhos que utilizam Aprendizado de Máquina no contexto da auditoria médica. A pesquisa se deu em três bases de dados, a saber: IEEE Explore,





ACM Digital e Science Direct. A partir das pesquisas nestas bases, chegou-se a nove artigos, sendo que oito referiam-se à auditoria de contas médicas e um se referia à auditoria na autorização.

No que tange às bases de dados utilizadas, seis trabalhos utilizaram o Medicare (Estados Unidos), dois outros fizeram a pesquisa em planos de saúde chineses e um deles trabalhou com uma base que mesclava dados de planos de saúde dos estados do Piauí e de Pernambuco. Apesar de ter sido identificado um trabalho com base de dados brasileira, o mesmo não tratava de auditoria nas contas médicas.

Verificou-se que o algoritmo de classificação *Random Forest* foi o que apresentou melhor acurácia nas aplicações a que foi submetido. Isto poderia dar o indicativo de que referido algoritmo poderia apresentar-se como uma solução boa para ser aplicada em bases de dados de contas médicas para auditoria no Brasil; porém, há de se pensar que o modelo americano de pagamento dos planos de saúde difere do brasileiro. No Brasil adota-se o *Fee for Service*.

Verificando os resultados alcançados em todos os trabalhos analisados, percebe-se que o uso do Aprendizado de Máquina para auditoria em contas médicas é de extrema valia, visto que o montante de dados a serem analisados a cada dia extrapola a capacidade humana. Além disto, a adoção de algoritmos de Aprendizado de Máquina pode diminuir o viés de análises humanas, as quais possuem uma série de fatores externos, sejam eles emocionais ou físicos do auditor.

Considerando os resultados obtidos nos artigos analisados, percebeu-se que apesar de bons resultados terem sido alcançados, as bases utilizadas ainda necessitam de um cuidado especial visto que muitos dados aparecem incompletos ou não são registrados, podendo causar um viés no uso massivo das técnicas de Aprendizado de Máquina. Para que estas técnicas possam ser usadas plenamente e possam trazer resultados eficientes, é necessário que as operadoras criem mecanismos que possam garantir a qualidade de suas bases de dados.

Verificou-se, também, que a fraude em pagamentos nos planos de saúde é um problema generalizado na área de saúde, seja no setor privado, como no caso dos Estados Unidos e Brasil, seja no setor público, como no caso da China.

A partir dos resultados desta pesquisa, será feito um estudo para aplicação de algoritmos de Aprendizado de Máquina nos dados de uma empresa de planos de saúde brasileira, com foco em contas médicas. Os resultados obtidos por tais algoritmos serão confrontados com os resultados obtidos pelos analistas humanos. Espera-se, então, criar um mecanismo computacional que possa contribuir com o avanço da área de auditoria em saúde no país.



Referências

- Agência Nacional de Saúde Suplementar (2019). *Dados e Indicadores do Setor*. Recuperado em 24 julho, 2019, de <http://www.ans.gov.br/perfil-do-setor/dados-e-indicadores-do-setor>.
- Alpaydin, E.. (2016). *Introduction to Machine Learning (3 rd ed..* MIT Press (MA)n.
- Brasil (1998). *Ministério da Saúde: Manual de Normas de Auditoria*. Recuperado em 20 d julho 2019, de http://bvsmms.saude.gov.br/bvs/publicacoes/manual_normas_auditoria.pdf.
- Bauder, R.A. , , Khoshgoftaar, T., M. (2016) A Probabilistic Programming Approach for Outlier Detection in Healthcare Claims. *Proceedings of 15th IEEE International Conference on Machine Learning and Applications. ICMLA 2016*, pp. 347–354.
- Bauder, R. A., Khoshgoftaar, T. M. (2017) Medicare fraud detection using machine learning methods. *Proceedings of 16th IEEE International Conference on Machine Learning and Applications. ICMLA 2017*, vol. 2018-jan, pp. 858–865.
- Bauder, R. A. (2018). Medicare Fraud Detection Using Random Forest with Class Imbalanced Big Data. *Proceedings of 2018 IEEE 19th Int. Conference on Information Reuse Integrated Data Science. IRI 2018*.
- Bauder, R. A., da Rosa, R. C., Khoshgoftaar, T. M. (2018). Identifying Medicare Provider Fraud with Unsupervised Machine Learning. *Proceedings of 2018 IEEE 19th Int. Conference on Information Reuse Integrated Data Science. IRI 2018*, pp. 285–292, 2018.
- Cassimiro, J. C., A Santana, A.M., Santos Neto, P., Rabelo, R.L. (2017). Investigating the Effects of Class Imbalance in Learning the Claim Authorization Process in the Brazilian Health Care Market. *Proceedings of 2017 International Joint Conference on Neural Networks (IJCNN)*, vol. 2017-May, pp. 3265–3272.
- Gao, Y. , Sun, C. , Li, R. Li, Q. , Cui, L. , Gong, B. (2018). *An Efficient Fraud Identification Method Combining Manifold Learning and Outliers Detection in Mobile Healthcare Services*. IEEE Access, vol. 6, pp. 60059–60068.
- Instituto de Estudos de Saúde Suplementar (2013). *Guia da Saúde Suplementar*. Recuperado em 24 julho, 2019, de <http://documents.scribd.com.s3.amazonaws.com/docs/jwfnp1a4g3pcsuj.pdf>.
- Instituto de Estudos de Saúde Suplementar (2018). *R\$ 28 bilhões em fraudes e desperdícios*. Recuperado em 24 julho 2018, de <https://www.iess.org.br/?p=blog&id=745>
- Instituto de Estudos de Saúde Suplementar (2019). *Beneficiários de planos médicos hospitalares*. Recuperado em 24 julho 2019, de <https://iessdata.iess.org.br/dados/bmh>.
- Minami, B. (2018). Sumário Executivo da Análise Especial do Mapa Assistencial da Saúde Suplementar no Brasil – Ano de 2018. Recuperado em 23 agosto, 2019, de <https://www.iess.org.br/cms/rep/sumapav3.pdf>.





Mueller, J. P. , Massaron, L. (2018). *Aprendizado de Máquina para Leigos*. Rio de Janeiro: AltaBooks. .

Russel, Stuart, Norvig, Peter (2013). *Inteligência Artificial* (3rd ed.). Rio de Janeiro: Editora Campus.

Seo, J. , Mendelevitch, O. (2017). Identifying Frauds and Anomalies in Medicare-B Dataset *Proceedings of 2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*.

Silva, J. A. S. V. , Hinrichsen, S. L. , Brayner, K. A. C. , Vilela, T. A. S.; Lemos, M. C. (2017). Glosas hospitalares e o uso de protocolos assistenciais: revisão integrativa da literatura. *Revista de Administração em Saúde*. Recuperado em 14 agosto, 2019 de <http://cqh.org.br/ojs-2.4.8/index.php/ras/article/view/13>.

Silva, V. D. , Scarpel, R. A. (2007). Detecção de fraudes na distribuição de energia elétrica utilizando support vector machine. *Investigação Operacional*, 27 (2007), 139-150. Recuperado em 12 agosto, 2019, de <http://www.scielo.mec.pt/pdf/iop/v27n2/v27n2a03.pdf>.

Silveira, G. , Bullock, B. (2017). *Machine Learning: introdução a classificação*. São Paulo: Editora Casa do Código.

Sun, C. , Li, Q. , Li, H. Shi, Y. , Zhang, S. , Guo, W. (2019). Patient Cluster Divergence Based Healthcare Insurance Fraudster Detection. *IEEE Access*, vol. 7, pp. 14162–14170.

Theobald, O. (2017). *Machine Learning for Absolute Beginners* (2nd ed.). Scatterplot Press.

Tike, A., Tavarageri, S. (2017). A Medical Price Prediction System using Hierarchical Decision Trees. *Proc. - 2017 IEEE International Conference on Big Data, Big Data 2017*, vol. 2018-Jan, pp. 3904–3913