

Detecção de Dados Suspeitos de Fraude em Organismos de Inspeção Acreditados

Rosembergue P. Souza¹, Luiz F. R. C. Carmo¹, Luci Pirmez²

¹Instituto Nacional de Metrologia, Qualidade e Tecnologia (Inmetro)
Av N. S. das Graças, 50, 25.250-020, Xerém - Duque de Caxias - Rio de Janeiro

²Programa de Pós Graduação em Informática Instituto Tércio Pacitti
Instituto de Matemática, Universidade Federal do Rio de Janeiro, 21.941-901, Rio de Janeiro

{rpereira,lfrust}@inmetro.gov.br, luci.pirmez@nce.ufrj.br

Abstract. *In recent years, there have been some news reports about fraud cases in activities regulated by Inmetro. Searching for new Information Technology tools to control these activities, this paper presents a mechanism to detect suspected fraud results in vehicle safety inspections. As a solution to the problem, the Markov Decision Process has been combined with Benford's Law. With the planning power of Markov Decision Process it is possible to find a subset of data with high probability of fraud.*

Resumo. *Nos últimos anos, algumas reportagens jornalísticas apontaram casos de fraudes em serviços regulamentados pelo Inmetro. Indo ao encontro de novas ferramentas de Tecnologia da Informação para acompanhamento de atividades regulamentadas pelo Inmetro, este trabalho apresenta um mecanismo para detecção de resultados suspeitos de fraude em inspeções de segurança veicular. O problema é solucionado usando Processo de Decisão de Markov combinado com a Lei de Benford. Através do poder de planejamento do Processo de Decisão de Markov é possível selecionar um subconjunto de dados com alto grau de suspeita de fraude.*

1. Introdução

Nos últimos anos, algumas reportagens jornalísticas repercutiram nacionalmente quando apontaram casos de fraudes em serviços regulamentados pelo Inmetro. Dois exemplos ilustram essa situação: o caso de fraude em bombas de combustível e o caso de roubo de combustível durante o transporte até os postos de venda. A fraude em bombas de combustível ocorreu através de controle remoto do volume de combustível que seria fornecido ao cliente. Por sua vez, o roubo de combustível durante o transporte até os postos de venda dava-se através da instalação de dois tanques no caminhão, sendo que um deles era destinado a desviar grande quantidade do produto.

O Inmetro tem procurado estabelecer ações de melhoria no acompanhamento dos serviços regulamentados pelo órgão. Uma dessas ações é o uso intensivo de ferramentas de Tecnologia da Informação (TI). Para ilustrar, tem-se a proposta de um sistema de acompanhamento da consistência de inspeções dos organismos acreditados na área equipamentos que transportam produtos perigosos através de critérios de plausibilidade [Machado et al. 2011]. Outro exemplo é a utilização de Rede Neurais de Kohonen para

identificar as características de possíveis organismos de inspeção fraudulentos na área equipamentos que transportam produtos [Souza et al. 2013].

Indo ao encontro de novas ferramentas de TI para acompanhamento de atividades regulamentadas pelo Inmetro, neste trabalho apresenta-se um mecanismo para detecção de resultados suspeitos de fraude em inspeções de segurança veicular. Os requisitos para a realização das inspeções de segurança veicular estão dispostos nas Portarias Inmetro Nº 30/2004, Nº 32/2004 e Nº 49/2010. Uma das etapas dessa inspeção é a verificação do grau de emissão de monóxido de carbono (CO) e hidrocarboneto (HC) pelos veículos inspecionados. A emissão destes gases por automóveis segue uma distribuição estatística do tipo gama [Guo et al. 2007], e conforme os veículos vão envelhecendo e acumulando quilômetros rodados a tendência é que o grau de emissão aumente [Wenzel et al. 2000]. A intenção de se inspecionar os veículos quanto a emissão de poluentes é manter o índice de emissão dentro dos valores estabelecidos pelos órgãos ambientais.

Somando-se a isso, as Portarias Inmetro Nº 30/2004, Nº 32/2004 e Nº 49/2010 estabelecem que toda inspeção deve ser conduzida por um organismo de inspeção autorizado pela Coordenação Geral de Acreditação do Inmetro (Cgcre/Inmetro). A Cgcre/Inmetro utiliza equipes de avaliadores para autorizar e supervisionar essas empresas. Logo, uma das formas de a Cgcre/Inmetro verificar se existem anomalias nos resultados das inspeções de seus organismos acreditados é se valendo de testes estatísticos.

Um dos testes estatísticos que se pode utilizar para verificar se houve adulteração em dados numéricos é a Lei de Benford. A Lei de Benford preconiza que, em alguns conjuntos de dados, a frequência de aparição dos dígitos mais significativos de um número segue uma distribuição logarítmica [Nigrini 2012]. Algumas distribuições estatísticas como a exponencial, gama e log-normal atendem a Lei de Benford de forma aproximada [Formann 2010]. Portanto, espera-se que os resultados dos ensaios de emissões de gases poluentes encontrados pelos organismos acreditados sigam de forma aproximada a Lei de Benford. No entanto, apenas o uso da Lei de Benford não é suficiente para confirmação de casos de fraude, mais investigações são sempre necessárias para se chegar a conclusão de fraude [Nigrini 2012]. Por isso, neste trabalho, para refinar os resultados da aplicação da Lei de Benford utiliza-se a técnica de Processo de Decisão de Markov - MDP (*Markov Decision Process*).

O Processo de Decisão de Markov é um problema de decisão sequencial para um ambiente completamente observável, estocástico, com um modelo de transição de Markov e recompensas aditivas [Russell and Norvig 2013]. A investigação realizada por auditores para verificar se a prestação de um serviço atende ou não a uma norma encaixa-se num problema de MDP. Um auditor, representando o agente do MDP, analisa registros em uma auditoria de forma sequencial. A cada novo registro analisado, o auditor decide qual fará parte de seu conjunto de evidências de atendimento a uma norma. Geralmente, não há tempo para analisar todos os registros produzidos por uma empresa, assim ele escolhe um subconjunto desses registros, onde cada registro possui uma probabilidade de ser escolhido.

Além disso, os registros coletados são ligados pelos seus atributos em comum, sendo que a escolha do próximo registro depende dos atributos do registro atual. Para aplicação de um MDP considerar-se-á que a escolha do próximo registro depende apenas

do atributos do registro atual. Registros anteriores não terão influência na decisão do próximo registro a compor um caso de suspeita de fraude. Com isso se estabelece a propriedade de Markov necessária a aplicação de um MDP. O objetivo da aplicação de um MDP é utilizar seu poder de planejamento para selecionar um subconjunto de dados com maior grau de suspeita de fraude.

Por fim, este trabalho está organizado da seguinte maneira: a seção 2 descreve os trabalhos relacionados, em seguida a seção 3 mostra alguns conceitos básicos, a seção 4 discorre sobre a proposta do trabalho, a seção 5 apresenta o estudo de caso e por sua vez a seção 6 mostra as conclusões e trabalhos futuros .

2. Trabalhos Relacionados

Existem trabalhos na literatura em que a Lei de Benford foi combinada com alguma técnica de inteligência artificial com o intuito de potencializar os resultados dessa lei.

Em [Bhattacharya et al. 2011], utiliza-se uma rede neural otimizada por algoritmos genéticos para classificar se um determinado conjunto de dados possui conformidade com a Lei de Benford ou não. Nesse trabalho, os autores conseguem, através da rede neural, unir testes estatísticos, medidas de teoria da informação e o coeficiente de correlação de Pearson para decidir sobre o atendimento a tal lei. Embora tenha sido um avanço na área, mais trabalho de investigação ainda é necessário para verificar quais são os elementos que estão causando os desvios identificados.

Em [Cantu and Saiegh 2011], a Lei de Benford é utilizada em conjunto com a técnica de Naive Bayes para classificação de eleições presidenciais quanto a sua legitimidade. Os autores utilizam a Lei de Benford para criação de dados sintéticos sobre eleições legítimas e fraudulentas, dada a dificuldade de se encontrar bancos de dados com exemplos desses tipos de eleições. Esses dados sintéticos são utilizados para treinamento da técnica de Naive Bayes. A validação do trabalho utiliza as eleições ilegítimas ocorridas na Argentina no período de 1931-1941, considerada a década infame desse país. A abordagem adotada permite a utilização direta dos desvios da Lei Benford para classificação da legitimidade de uma eleição, não havendo a necessidade de se verificar os elementos que causaram o não atendimento a essa lei.

Em [Lu 2007], usa-se a Lei de Benford com a técnica de Aprendizagem por Reforço. O intuito é aproveitar a característica exploratória da Aprendizagem por Reforço para conectar atributos de um conjunto de dados com alto grau de anomalia. A técnica de Aprendizagem por Reforço é similar a um Processo de Decisão de Markov, a diferença consiste no fato de que na Aprendizagem por Reforço não se conhece a função de probabilidades de transição entre estados, nem a função de recompensa. O agente descobre a política ótima para um determinado ambiente através de tentativa e erro. Essa combinação de técnicas permite o refinamento dos resultados obtidos pela Lei de Benford. No entanto, a necessidade de recurso computacional aumenta a medida que o número de dados a serem analisados aumenta.

Assim, neste trabalho, combina-se a Lei de Benford com a técnica de Processo de Decisão de Markov para se montar um caso de fraude. De forma similar a [Lu 2007], a intenção é conectar atributos dos elementos de um conjunto maximizando o grau de anomalia entre eles. Para isso, o conjunto de dados disponível é modelado nos elementos

que compõem um MDP. Esta modelagem permite o uso de programação dinâmica para se encontrar uma política ótima. A obtenção dessa política ótima é feita de forma mais rápida usando-se MDP do que Aprendizagem por Reforço, visto que não se precisa visitar os estados do ambiente um número infinito de vezes para se chegar ao ponto ótimo.

3. Fundamentação

3.1. Lei de Benford

Segundo a Lei de Benford, em alguns conjuntos de dados, a frequência de aparição dos dígitos mais significativos segue uma distribuição logarítmica [Nigrini 2012]. As equações 1 e 2 apresentam as fórmulas das probabilidades esperadas para o primeiro e para os dois primeiros dígitos mais significativos respectivamente:

$$P(D_1 = d_1) = \log \left(1 + \frac{1}{d_1} \right) \quad (1)$$

$$P(D_1 D_2 = d_1 d_2) = \log \left(1 + \frac{1}{d_1 d_2} \right) \quad (2)$$

onde D_1 , representa o primeiro dígito mais significativo, $D_1 D_2$ representa os dois primeiros dígitos mais significativos, $d_1 \in \{1, 2, 3, \dots, 9\}$ e $d_1 d_2 \in \{10, 11, 12, 13, \dots, 99\}$.

Segundo [Nigrini 2012], a Lei de Benford só pode ser aplicada a uma amostra de dados se as seguintes condições forem satisfeitas: i) os dados dessa amostra devem conter informação de tamanho de fatos ou eventos. Por exemplo, tamanho de cidades, vazão de rios e lucro de empresas; ii) a amostra não deve possuir mínimos e máximos embutidos, exemplo: um fundo de investimento com valor mínimo de R\$500,00 de aplicação; iii) os elementos da amostra não podem ser dados de identificação, como número de telefone e placas de veículos; iv) a média dos dados deve ser menor que a mediana e os dados não devem ficar fortemente agrupados em torno do valor médio.

3.2. Processos de Decisão de Markov

Um Processo de Decisão de Markov é uma tupla (S, A, T, R) onde: S é o conjunto de estados, A é o conjunto de ações, $T : S \times A \times S \rightarrow [0, 1]$ é uma função de probabilidade de transição do estado $s \in S$ para $s' \in S$, dado uma ação $a \in A$ (denotada por $T(s' | s, a)$) e $R : S \times A \rightarrow \mathbb{R}$ é uma função que dá o custo (ou recompensa) quando o agente está no estado $s \in S$ toma uma decisão $a \in A$ e vai para o estado $s' \in S$ (denotada por $R(s' | s, a)$) [David and Alan 2010]. O nome Markov se deve a propriedade Markoviana (sem memória), isto é a definição do próximo estado do agente só depende do estado atual. Uma política π é uma função que mapeia estados em ações, sendo que o objetivo do Processo de Decisão de Markov é encontrar uma política que maximize sua recompensa acumulada ao longo prazo. Uma forma de se medir o desempenho do agente num MDP é usando o critério de recompensa esperada descontada $E \left[\sum_{k=0}^{\infty} \gamma^k r_k \right]$, onde r_k é a recompensa no passo k e γ é o fator de desconto, que é usado para garantir a convergência do valor da recompensa total esperada.

A função $V^\pi(s)$ é o valor esperado da recompensa descontada para o agente que sai do estado s e segue a política π . Já a função $Q^\pi(s, a)$ é o valor da recompensa esperada

descontada quando o agente sai do estado s escolhendo a ação a e seguindo a política π . A função de valor $V^*(s)$ ótima é definida como $V^*(s) = \max(V(s))$ para todo $s \in S$. Valendo também $V^*(s) = \max_a(Q^*(s, a))$ e $\pi^* = \operatorname{argmax}_a(Q^*(s, a))$. Existe uma grande quantidade de algoritmos para a solução de um MDP. Alguns trabalham diretamente com políticas, enquanto outros trabalham com funções valor, detalhes sobre esses algoritmos podem ser encontrados em [David and Alan 2010].

4. Proposta

O mecanismo de detecção de dados suspeitos de fraude proposto neste trabalho inicia-se aplicando a Lei de Benford na amostra de dados. A Lei de Benford é utilizada para determinar a função de recompensa do MDP. Tendo em mãos a função de recompensa, a tabela de dados da amostra passa por um processo de discretização dos atributos. Em seguida, define-se a função de probabilidade de transição entre estados. Daí, uma política ótima é estabelecida. Com esta política ótima, explora-se a amostra de dados e apresenta-se uma lista com os casos de suspeita de fraude. A figura 1 mostra as etapas do processo para detecção de dados suspeitos de fraudes usando MDP.

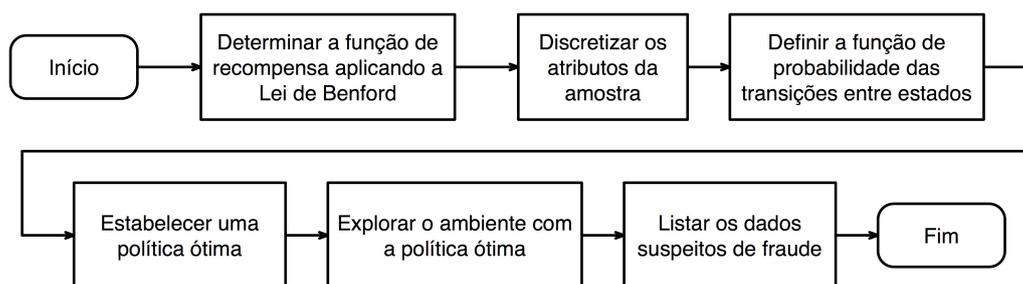


Figura 1. Representação gráfica da detecção de dados suspeitos de fraude usando Processo de Decisão de Markov.

4.1. Definindo a função de recompensa usando a Lei de Benford

Para que se possa aplicar o Processo de Decisão de Markov, faz-se necessário definir a função de recompensa $R(s' | s, a)$. A fim de facilitar a compreensão dessa definição, é preciso caracterizar o conjunto de ações e de estados do MDP.

Primeiramente usa-se uma representação tabular, onde cada linha da tabela representa um elemento da amostra de dados e cada coluna representa um atributo desse elemento. As linhas são o conjunto de estados possíveis S , onde cada linha é um estado s . Os atributos são o conjunto de ações A , sendo cada atributo uma ação a . A tabela 1 ilustra como são representados os estados e ações. No exemplo mostrado nessa tabela, os dados contém informações sobre ensaios de emissões veiculares de gases poluentes. Os atributos são Vel velocidade de rotação do motor em marcha alta em rpm na hora do ensaio, $Fdil$ fator de diluição dos gases do ensaio, CO índice percentual de emissão de monóxido de carbono, CO_2 índice percentual de emissão de dióxido de carbono e HC índice de emissão de Hidrocarboneto em ppm.

A recompensa de cada estado é associada com o grau de anomalia daquele estado. Neste trabalho, para definir esse grau de anomalia usou-se a Lei de Benford. A tabela 1 ilustra a forma como as recompensas foram definidas. Para aplicação da Lei de Benford considerou-se apenas os dados de emissão de HC, denominado, neste trabalho, como indicação “Alvo”.

Tabela 1. Ilustração do conjunto de estados, ações e recompensas

Estados	Atributos					Recompensa
	Ações				Alvo	
	Vel (rpm)	Fdil	CO(%)	CO2(%)	HC(ppm)	
1	2571	1,67	0,13	8,83	42	0,84
2	2479	1,12	0,44	12,83	129	0,98
3	2547	1,00	0,01	13,51	16	1,19
4	2426	1,11	0,00	13,49	22	1,18

Como dito anteriormente, os valores de HC seguem uma distribuição estatística gama, logo espera-se que esses valores atendam a Lei de Benford de forma aproximada. Assim, o grau de anomalia de cada estado é determinado pelo grau de desvio que os valores de HC têm perante a Lei de Benford. O grau de anomalia de cada estado s é calculado usando equação 3 descrita abaixo

$$Grau\ anomalia(s) = \frac{Prob_{observada}(s)}{Prob_{esperada}(s)} \quad (3)$$

onde $Prob_{observada}$ é a frequência observada dos dígitos mais significativos na amostra de dados e $Prob_{esperada}$ é a frequência esperada dos dígitos mais significativos segundo a Lei de Benford [Lu 2007]. A equação 4 define a função de recompensa do MDP

$$R(st | s, a) = Grau\ anomalia(st) = \frac{Prob_{observada}(st)}{Prob_{esperada}(st)} \quad (4)$$

Por exemplo, se forem usados os dois dígitos mais significativos dos elementos de uma amostra e considerando o valor de HC no estado 1 da tabela 1, tem-se $D_1 = 4, D_2 = 2$. Suponha que essa combinação dos dois dígitos mais significativos apareça 12 vezes numa amostra de dados de HC com 1400 elementos, então se teria $Prob_{observada} = 12/1400 = 0,0086$. A probabilidade esperada para os dois dígitos mais significativos quando $D_1 = 4, D_2 = 2$ é, segundo a equação 2, $Prob_{esperada} = 0,0102$. Portanto, o grau de anomalia/recompensa do estado 1 é 0,84.

4.2. Discretização dos dados

Com o intuito de se aplicar a técnica de Processo de Decisão de Markov, fez-se necessário discretizar os atributos da amostra. Quando os elementos da amostra não possuem classes atribuídas a eles, deve-se se lançar mão de técnicas de discretização não-supervisionadas.

Na literatura, existem duas técnicas bastante simples para discretização não-supervisionada, a primeira estabelece intervalos com larguras iguais e a segunda estabelece um número uniforme de elementos por intervalo. O número de intervalos N_{int} é escolhido *a priori* em ambas as técnicas [Garcia et al. 2013]. Neste trabalho, adotou-se a segunda técnica de discretização, pois a primeira pode retornar intervalos muito populosos e outros intervalos com poucos elementos, deixando o resultado da discretização enviesado. A tabela 2 mostra um exemplo de atributos discretizados, supondo um número de 200 intervalos. A coluna alvo não é mostrada, pois já foi utilizada para a determinação das recompensas.

4.3. Definindo a função transição de probabilidades T

A solução de um MDP consiste em estabelecer uma política ótima levando em conta a tupla (S, A, T, R) . Até o momento, já foram modelados o conjunto de estados S , o conjunto de ações A e a função de recompensa R . O próximo passo é definir a função de probabilidades T .

Para se definir a função T , primeiro deve-se ter em mente que os estados são conectados através de atributos em comum. Considerando o método de discretização utilizado, onde o número de elementos N_e por intervalo é uniforme, apenas elementos de mesmo intervalo podem formar estados conectados. Admitindo transições equiprováveis, a probabilidade do agente sair de um estado s para um estado s' escolhendo uma determinada ação a será $\frac{1}{N_e}$. Como o número de elementos de cada intervalo $N_e = N_s/N_{int}$, então a probabilidade de transição de um estado para o outro é $\frac{1}{N_e} = \frac{N_{int}}{N_s}$. Assim, a função de transição $T(s' | s, a)$ pode ser definida pela equação

$$T(s' | s, a) = \frac{N_{int}}{N_s} \quad (5)$$

onde N_s é o número total de estados.

Tabela 2. Atributos com valores discretizados

Estados	Atributos/Ações				Recompensa
	Vel (rpm)	Fdil	CO(%)	CO2(%)	
5	110	1	166	91	1,41
6	126	173	158	31	1,22
7	9	1	167	94	0,49
8	135	1	160	41	1,11

Para exemplificar como as transições entre estados acontecem, considere que o agente só pode transitar entre os estados mostrados na tabela 2. A figura 2 mostra o diagrama de transições da mudança de estados que o agente pode realizar nessa situação. Suponha que o agente está no estado 5 e escolhe a ação $Fdil$, o conteúdo de $Fdil$ no estado 5 é 1, logo os estados 7 e 8 estão conectados a 5. Uma vez escolhida a ação $Fdil$ no estado 5, e se verificando os estados conectados a esse estado, a decisão do próximo estado do agente será feita através de um sorteio. Cada próximo estado tem

a mesma probabilidade de ser sorteado. Inclui-se nesse sorteio também o estado 5, já que ele próprio possui o conteúdo 1. Isso significa que o agente pode tomar uma ação e permanecer em seu estado atual. Assumindo transições equiprováveis, a probabilidade de transição entre os estados 5, 7 e 8 é de $1/3$. Caso no sorteio o agente saia do estado 5 e caia no estado 8, ele recebe a recompensa 1, 11. Isto é representado na figura 2 pela tupla $(1; 0,333; 1,11)$, onde o primeiro elemento representa o valor da ação escolhida, o segundo representa a probabilidade da transição e o terceiro, a recompensa a ser recebida ao final da transição.

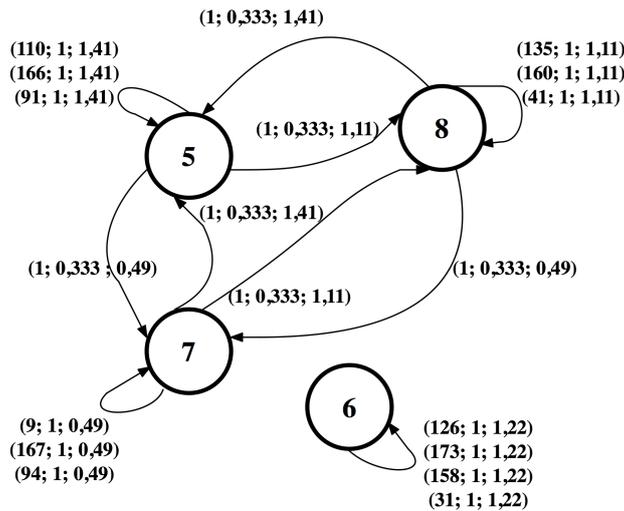


Figura 2. Representação gráfica do diagrama de transições.

4.4. Estabelecendo uma política ótima

Uma vez que a tupla (S, A, T, R) da MDP está definida, pode-se utilizar o algoritmo 1 para se encontrar uma política ótima.

O algoritmo 1 é chamado de iteração de valor assíncrona, pois o cálculo da função $Q(s, a)$ para cada par estado-ação é realizado em qualquer ordem. Além disso, vale destacar que o critério de parada indica que a diferença absoluta entre a função de valor $V(s)$ e a função de valor ótima $V^*(s)$ é menor que ϵ para todo s . Por fim, o algoritmo retorna a função $Q^*(s, a)$ para que seja obtida uma política sub-ótima. Este tipo de política será utilizada posteriormente em experimentos abordados neste trabalho.

4.5. Explorando o ambiente com a política ótima

De posse da política ótima, o agente deve explorar a amostra de dados para listar os elementos suspeitos de fraude. De forma similar a [Lu 2007], a exploração ocorrerá em episódios. Um episódio é o trajeto do agente do estado inicial ao estado final. O estado inicial considerado neste trabalho é o estado cuja função de valor de estado é máxima, o estado final será qualquer estado previamente visitado.

4.6. Lista dos dados suspeitos de fraude

O agente, usando a política ótima obtida, visitará vários estados dentro da amostra de dados considerada. A lista de elementos suspeitos de fraude são todos esses estados visitados.

Algoritmo. 1 Iteração de Valor Assíncrona($S, A, R, T, \gamma, \epsilon$). Algoritmo para encontrar uma política ótima de um MDP.

```

1  início
2  inicia  $\pi(s)$  arbitrariamente
3  inicia  $Q(s, a)$  arbitrariamente
4  inicia  $V_k(s)$  com zeros
5   $k := 0$ 
6  repita
7     $k := k + 1$ 
8    seleciona randomicamente estado  $s$ 
9    seleciona randomicamente ação  $a$ 
10    $Q(s, a) := \sum_{s'} T(s' | s, a)(R(s' | s, a) + \gamma \max_{a'} Q(s', a'))$ 
11    $V_{k-1}(s) := V_k(s)$ 
12    $V_k(s) := \max_a Q(s, a)$ 
13   até  $\forall s \mid V_k(s) - V_{k-1}(s) < \frac{\epsilon(1-\gamma)}{\gamma}$ 
14   para cada estado  $s$  faça
15      $\pi^*(s) := \operatorname{argmax}_a Q^*(s, a)$ 
16   retorna  $\pi^*, Q^*(s, a)$ 
17 fim

```

5. Resultados

O desempenho do mecanismo proposto neste trabalho foi medido através de 4 experimentos. Esses experimentos foram elaborados usando linguagem C do programa MATLAB®. Tais testes foram utilizados para verificar a capacidade do mecanismo em determinar um subconjunto de elementos onde se tenha o máximo grau de suspeita de fraude. Para isso, tomou-se uma amostra de 1400 ensaios de emissão veicular de gases poluentes obtidos num organismo acreditado e tabulados numa planilha Excel®. Nessa amostra, escolheu-se aleatoriamente uma quantidade predeterminada de ensaios. Nesses ensaios escolhidos aleatoriamente, foi alterada a medida de HC por um valor constante qualquer. No fim, aplicou-se o mecanismo proposto neste trabalho para verificar quantos elementos alterados eram detectados. A equação 6 mostra a métrica utilizada na medição do desempenho

$$TA_{med} = \frac{N_{alt}}{N_{rec}} \quad (6)$$

onde TA_{med} é a taxa média de acerto, N_{alt} é o número de elementos alterados e N_{rec} é o número de elementos recomendado pelo mecanismo proposto neste trabalho como sendo os mais anômalos. A média é calculada por episódio de exploração. A figura 3 mostra parte do conjunto de dados utilizados nos experimentos deste trabalho. Os atributos Vel , $Fdil$, CO , CO_2 e HC são como explicados anteriormente.

Em todos os experimentos considera-se $\gamma = 0,9$, $\epsilon = 0,001$ e 121 episódios de exploração. Esse número de episódios de exploração foi escolhido para que se tivesse num

F	G	H	I	J
Vel (rpm)	FDIL	CO (%)	CO2(%)	HC(ppm)
2589	1,09781033	0,0973125	13,56625	34,5625
2431	1,09901684	0,0754375	13,573125	40,9375
2574	1,11591575	0	13,441875	28,375
2414	1,12238694	0	13,364375	26,8125
2666	1,11198113	0,0500625	13,439375	55,6875
2475	1,10639867	0	13,5575	49,75
2571	1,67256711	0,13575	8,8325	42

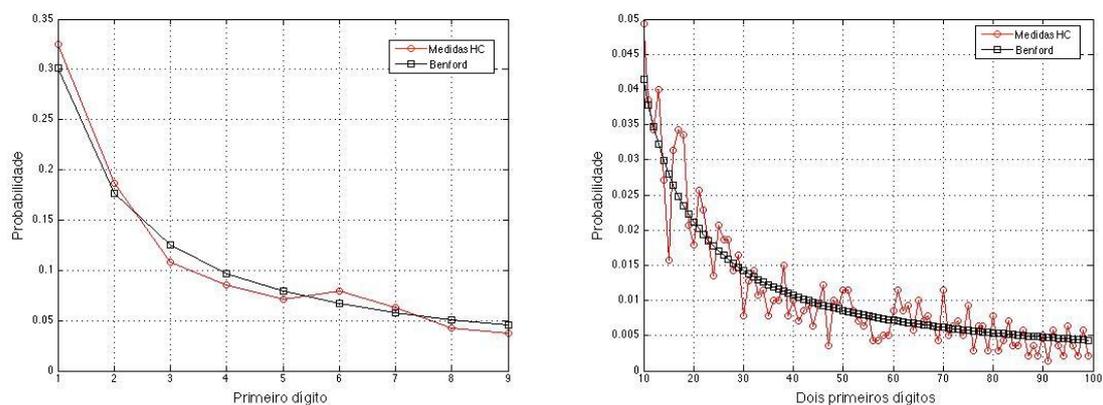
Figura 3. Parte dos dados utilizados nos experimentos deste trabalho.

número de graus de liberdade de 120. Com esse número de graus de liberdade, calculou-se os limites do intervalo de confiança da taxa média de acerto usando a distribuição estatística t e intervalo de confiança de 5%.

5.1. Experimento 1

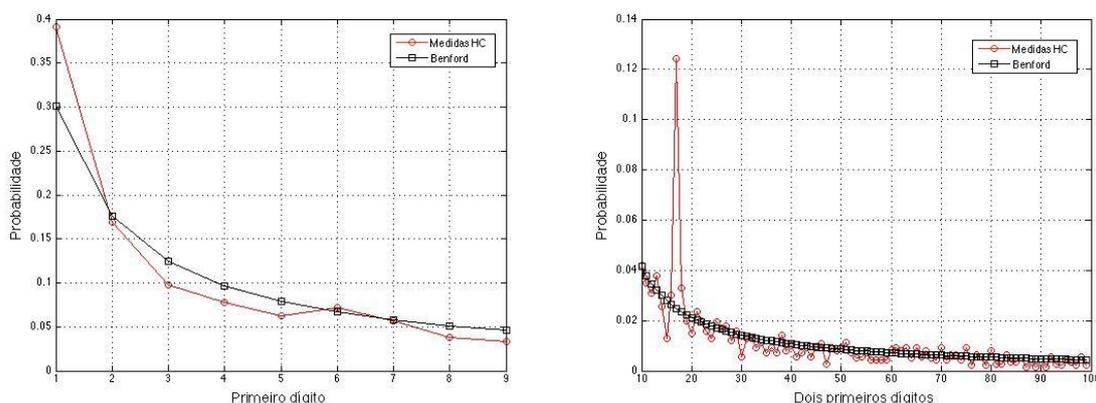
Nesse primeiro experimento, o intuito é investigar de que forma a definição da função de recompensa pode influenciar na taxa média de acerto do mecanismo proposto neste trabalho. Duas opções foram utilizadas para definição da função de recompensa. A primeira opção considerou o grau de anomalia dado pela Lei de Benford usando apenas o primeiro dígito mais significativo. A segunda opção considerou os dois primeiros dígitos mais significativos.

As figuras 4 e 5 mostram os resultados obtidos a partir da aplicação da Lei de Benford ao conjunto de valores de HC. A figura 4 mostra a aplicação da Lei de Benford considerando que os dados não sofreram nenhum tipo de adulteração. Já a figura 5 mostra a aplicação da Lei de Benford quando 140 valores de HC foram escolhidos aleatoriamente e adulterados para o valor de 17 ppm. Nota-se na figura 5(a) que o dígito 1 apresenta o maior grau de anomalia. Na figura 5(b), o número 17 apresenta maior grau de anomalia. Ambas as figuras 5(a) e 5(b) indicam sinais de adulteração dos dados de HC.



(a) Lei de Benford com o primeiro dígito mais significativo (b) Lei de Benford com os dois primeiros dígitos mais significativos

Figura 4. Aplicação da Lei de Benford no conjunto de valores de HC considerando o primeiro dígito mais significativo e os dois primeiros dígitos mais significativos sem adulterações.



(a) Lei de Benford com o primeiro dígito mais significativo (b) Lei de Benford com os dois primeiros dígitos mais significativos

Figura 5. Aplicação da Lei de Benford considerando o primeiro dígito mais significativo e os dois primeiros dígitos mais significativos. No conjunto de valores de HC há 140 valores adulterados para 17 ppm.

Tabela 3. Desempenho considerando primeiro e segundo dígitos

Dígito mais significativo	Taxa média de acerto
Primeiro	0,00 ± 0,00
Dois primeiros	0,46 ± 0,03

Considerando o grupos de dados adulterados, aplica-se o MDP afim de se identificar quais elementos foram adulterados. Usou-se o processo de discretização de atributos com número de intervalos $N_{int} = 200$. A tabela 3 mostra os valores da taxa média de acerto.

Observa-se que usando os dois dígitos mais significativos pôde-se identificar mais elementos adulterados. O uso da Lei de Benford considerando os dois dígitos mais significativos permitiu focar as maiores recompensas nos valores que possuíam 1 e 7 como os dois primeiros dígitos mais significativos. Isso aumentou a chance de se encontrar mais elementos adulterados.

5.2. Experimento 2

Nesse segundo experimento, investiga-se a forma como a definição do número de intervalos pode influenciar na taxa média de acerto do mecanismo proposto neste trabalho. Para tal, tomou-se os seguintes números de intervalos $N_{int} = 100$, $N_{int} = 200$ e $N_{int} = 280$. A função de recompensa foi definida pela Lei de Benford usando os dois primeiros dígitos mais significativos. Considera-se ainda que o número de elementos adulterados é de 140 valores, todos adulterados para o valor de 17 ppm de forma aleatória. A tabela 4 mostra os valores da taxa média de acerto para cada valor de N_{int} .

O número de intervalos tem influência direta na função de probabilidade das transições entre estados, bem como no número de estados que podem ser conectados entre si. Nota-se na tabela 4 que, aumentando o número de intervalos, tem-se um melhora na

Tabela 4. Desempenho considerando o número de intervalos

Intervalos	Taxa média de acerto
100	0,23 ± 0,03
200	0,46 ± 0,03
280	0,67 ± 0,04
350	0,18 ± 0,03

taxa média de acerto. No entanto, aumentar excessivamente o número de intervalos diminui a capacidade de acerto, já que diminui o número de estados que podem ser conectados entre si.

5.3. Experimento 3

Nesse terceiro experimento, verifica-se o efeito de se ter diferentes números de valores de HC adulterados. A função de recompensa foi definida pela Lei de Benford usando os dois primeiros dígitos mais significativos. Considera-se número de intervalos discretizados $N_{int} = 200$. Os valores de HC foram adulterados para o valor de 17 ppm de forma aleatória.

Tabela 5. Desempenho considerando número de elementos alterados

Número de alterações de HC	Taxa média de acerto
14	0,00 ± 0,00
60	0,00 ± 0,00
140	0,46 ± 0,03
280	0,47 ± 0,04
320	0,69 ± 0,04

A tabela 5 mostra a taxa média de acerto quando o número de valores adulterados varia. Nota-se nessa tabela que quanto mais dados adulterados mais o mecanismo proposto neste trabalho consegue acertar. No entanto, é importante destacar que a Lei de Benford possui baixa sensibilidade. Quando poucos dados são modificados, a técnica não consegue destacar essas adulterações.

5.4. Experimento 4

Por fim, neste quarto experimento, investiga-se a influência de se usar uma política ótima e outra sub-ótima para se listar os dados suspeitos de adulteração. A função de recompensa foi definida pela Lei de Benford usando os dois primeiros dígitos mais significativos. Considera-se número de intervalos discretizados $N_{int} = 200$. Os valores de HC foram adulterados para o valor de 17 ppm de forma aleatória. O número de valores adulterados foi de 140.

A tabela 6 mostra a taxa média de acerto quando se usa a política ótima e quando se usa a política sub-ótima. Como era de se esperar, usando a política ótima o agente consegue encontrar mais valores adulterados do que usando a política sub-ótima.

Tabela 6. Desempenho considerando política ótima e subótima

Política	Taxa média de acerto
Ótima	0,46 ± 0,03
Sub-ótima	0,11 ± 0,02

Por ilustração, a figura 6 mostra um episódio de exploração da amostra de dados e a lista de dados suspeitos de adulteração. Nesse exemplo, o mecanismo proposto neste trabalho recomenda quatro ensaios como adulterados, e consegue acertar os quatro.

```

Episódio( 20.000000 ).
( 182.00 ) - Vel(rpm) - 2441.00 Fdil - 1.17 CO - 0.36 - CO2 - 12.47 HC - 17.00
( 321.00 ) - Vel(rpm) - 2513.00 Fdil - 1.17 CO - 0.72 - CO2 - 12.11 HC - 17.00
( 770.00 ) - Vel(rpm) - 2374.00 Fdil - 1.17 CO - 0.00 - CO2 - 12.83 HC - 17.00
( 919.00 ) - Vel(rpm) - 2483.00 Fdil - 1.17 CO - 0.86 - CO2 - 11.97 HC - 17.00

```

Figura 6. Lista de ensaios suspeitos de fraude com política ótima, 4 recomendações e 4 acertos.

Já a figura 7 mostra um exemplo de episódio onde a lista de dados suspeitos de adulteração é dada pelo uso da política sub-ótima. Embora liste mais valores como sendo suspeitos, só um deles foi de fato adulterado.

```

Episódio( 120.000000 ).
( 1.00 ) - Vel(rpm) - 2589.00 Fdil - 1.10 CO - 0.10 - CO2 - 13.57 HC - 34.56
( 190.00 ) - Vel(rpm) - 2340.00 Fdil - 1.09 CO - 0.00 - CO2 - 13.79 HC - 18.50
( 208.00 ) - Vel(rpm) - 2463.00 Fdil - 1.10 CO - 0.00 - CO2 - 13.70 HC - 63.69
( 414.00 ) - Vel(rpm) - 2526.00 Fdil - 1.09 CO - 0.02 - CO2 - 13.68 HC - 14.75
( 663.00 ) - Vel(rpm) - 2534.00 Fdil - 1.10 CO - 0.13 - CO2 - 13.57 HC - 17.00

```

Figura 7. Lista de ensaios suspeitos de fraude com política sub-ótima, 5 recomendações e 1 acerto.

6. Conclusões

Neste trabalho, foi apresentada uma aplicação de MDP para selecionar um subconjunto de dados com suspeita de fraude. Este tipo de mecanismo pode auxiliar os auditores da Cgcre/Inmetro a identificar anomalias durante as avaliações de supervisão dos organismos acreditados em segurança veicular. Mostrou-se que o uso da Lei de Benford considerando os dois dígitos mais significativos foi eficaz na identificação elementos adulterados. Além disso, apresentou-se que o número de intervalos de discretização pode influenciar na capacidade de acerto do mecanismo proposto. Somando-se a isso, constatou-se que a Lei de Benford possui baixa sensibilidade. Um número pequeno de dados adulterados não pode ser identificado por essa técnica. Para trabalhos futuros, pretende-se explorar outras técnicas estatísticas para determinação do grau de anomalia, outras formas de adulteração de dados, formas de identificação das causas das anomalias e os itens adulterados.

Referências

Bhattacharya, S., Xu, D., and Kumar, K. (2011). An ann-based auditor decision support system using benford's law. In *Decision Support Systems*, volume 50, pages 576–584. Elsevier B.V.

- Cantu, F. and Saiegh, S., M. (2011). Fraudulent Democracy? An Analysis of Argentina's Infamous Decade Using Supervised Machine Learning. In *Political Analysis*, volume 19, pages 409–433.
- David, L. P. and Alan, K. M. (2010). *Artificial Intelligence Foundations of Computational Agents*. Cambridge University Press, 1st edition.
- Formann, A., K. (2010). The Newcomb-Benford law in its relation to some common distributions. In *PloS one*, volume 5.
- Garcia, S., Luengo, J., and Sáez, J. (2013). A survey of discretization techniques: Taxonomy and empirical analysis in supervised learning. In *IEEE Transactions on Knowledge and Data Engineering*, volume 25, pages 734–750.
- Guo, H., Zhang, Q., Shi, Y., and Wang, D. (2007). On-road remote sensing measurements and fuel-based motor vehicle emission inventory in hangzhou, china. In *Atmospheric Environment*, volume 41, pages 3095–3107.
- Lu, F. (2007). Uncovering Fraud in Direct Marketing Data with a Fraud Auditing Case Builder. In *Lecture Notes in Computer Science 4702*, pages 540–547.
- Machado, R., C., Boccardo, D., R., Carmo, L., F. R. C., Prado, C., B., Nascimento, Tiago., M., Ribeiro, L., C., and Oliveira, T., D. (2011). Sistema de acompanhamento de inspeções de produtos perigosos. In *Anais do VI Congresso Brasileiro de Metrologia*.
- Nigrini, M. (2012). *Benford's Law Applications for Forensic Accounting, Auditing, and Fraud Detection*. John Wiley & Sons, 1st edition.
- Russell, S. and Norvig, P. (2013). *Artificial Intelligence A Modern Approach*. Elsevier, 3rd edition.
- Souza, R., Carmo, L., F. R. C., Boccardo, D., R., Pirmez, L., and Machado, R., C. (2013). Redes de kohonen para detecção de fraudes em inspeções na área de transporte de produtos perigosos. In *Anais do VII Congresso Brasileiro de Metrologia*.
- Wenzel, T., Singer, B., C., and Slott, R. (2000). Some issues in the statistical analysis of vehicle emissions. In *Journal of Transportation Statistics*, pages 1–14.