

Modelagem do Perfil de Atendimento aos Idosos nas Unidades de Saúde de Curitiba

Priscila L. L. Santin, Anelise Munaretto, Mauro Fonseca

Universidade Tecnológica Federal do Paraná (UTFPR) – Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial (CPGEI) – Curitiba – PR – Brasil

{priscilasantin, anelise, maurofonseca}@utfpr.edu.br

Abstract. *The increase in the people life expectancy together with decline in birth rates has made the aging population catch the attention of the govern. Essential and special care must be assured to ensure the health of the elderly population. This work proposes an approach based on stochastic evaluation to model care for the elderly in the health units of Curitiba, given the database of attendance to the population in the health posts is incomplete or poorly filled. The work considers the profile of the elderly separately from the other patients, aiming to increase the modeling efficiency. The experimental results reached success rates around 97%, showing the feasibility of the proposal.*

Resumo. *O aumento da expectativa de vida das pessoas aliado à diminuição das taxas de natalidade fez o envelhecimento populacional chamar a atenção do poder público. Cuidados essenciais e especiais devem ser assegurados a saúde da população idosa. Este trabalho propõe uma abordagem baseada em avaliação estocástica para modelar os atendimentos aos idosos nas unidades de saúde de Curitiba, pois a base de dados de atendimento à população nos postos de saúde está incompleta ou mal preenchida. No trabalho é considerado o perfil dos idosos em separado dos demais pacientes, visando aumentar a eficiência da modelagem. Os resultados experimentais atingiram taxas de acerto em torno de 97%, mostrando a viabilidade da proposta.*

1. Introdução

O envelhecimento populacional é um fenômeno caracterizado pelo aumento da expectativa de vida das pessoas e a diminuição das taxas de natalidade. Essa transição demográfica originou-se na Europa logo após a Revolução Industrial com o surgimento da pílula anticoncepcional. O envelhecimento populacional sugere, além de outros fatores, uma reorganização do sistema de Saúde, pois com uma população mais idosa aumentam os custos do sistema de saúde público, devido aos cuidados que a saúde dos idosos demanda.

No Brasil, o envelhecimento populacional passou a ser observado a partir de 1960. Segundo o IBGE (Instituto Brasileiro de Geografia e Estatística) [IBGE 2016], em 1940 a população brasileira era composta por 42% de jovens com idade inferior a 15 anos, e por 2,5% de idosos. No último Censo realizado pelo IBGE, em 2010, a população de jovens reduziu-se a 24% do total e os idosos passaram a 10,8% do povo brasileiro, representando um incremento de 400% se comparado ao índice anterior.

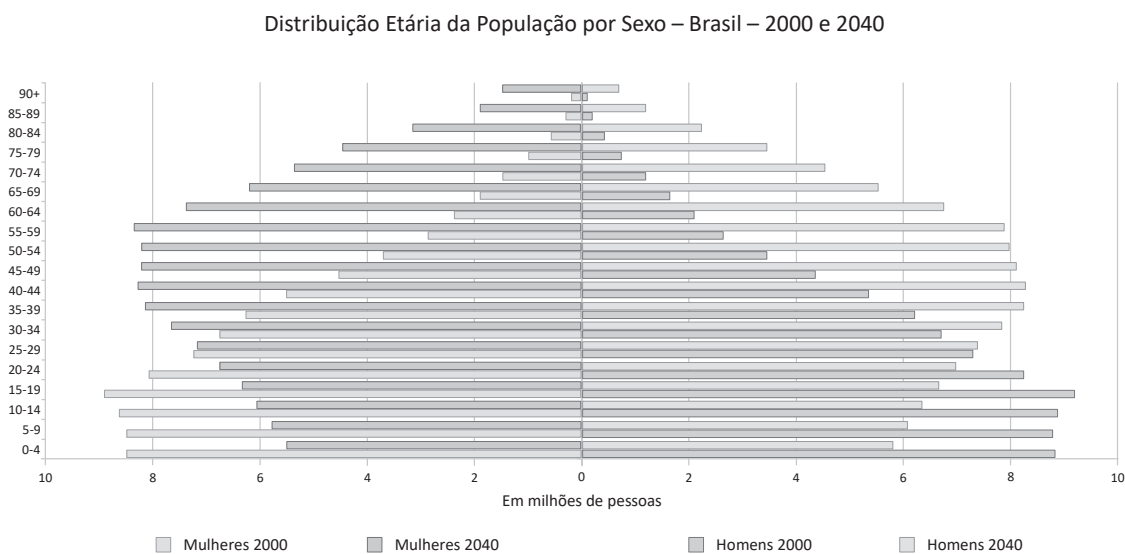


Figura 1 - Projeção do IPEA quanto a distribuição etária até 2040.

A Figura 1 traz uma projeção do IPEA (Instituto de Pesquisa Econômica Aplicada) [IPEA 16] com uma comparação da distribuição etária da população para o Brasil para os anos de 2000 e 2040. É possível observar que a distribuição passa de um formato piramidal em 2000, onde a população jovem se apresentava em maior quantidade, para um formato de losango em 2040, quando a maioria da população estará com idade entre 35 e 55 anos.

O cuidado com os idosos é muito importante para prover-lhes qualidade de vida e para diminuir gastos públicos com o tratamento da saúde deste público. Assim, as campanhas de vacinação, prevenção de doenças e exames de rotina são primordiais para atingir tal objetivo. Mensalmente, cerca de 20% dos atendimentos nas unidades de saúde de Curitiba são voltados ao público idoso.

Para estudar o comportamento dos idosos e poder tornar os atendimentos nas unidades de saúde mais eficientes, fazendo com que as companhias de saúde alcancem mais facilmente esta população, é necessário modelar o comportamento dos mesmos.

Quando se começa a lidar com base de dados pública sobre o atendimento a pacientes nas unidades de saúde se percebe que os hábitos dos atendentes ou rotina da unidade fazem com que a base de dados de atendimento seja incompleta ou erroneamente preenchida, o que dificulta a modelagem. Se os campos da base não estão preenchidos corretamente, os vetores de características (atributos) dos pacientes não são montados corretamente, e o modelo fica impreciso. Assim, a primeira dificuldade no tratamento dos dados é identificar os registros de idosos entre os demais pacientes, pois na maioria dos métodos, é necessário o preenchimento de todos os campos da base para se fazer a classificação.

O único método que consegue modelar um número de atributos variável é o modelo markoviano, que considera a hipótese de obter-se a classificação mesmo considerando as condições da base.

Este artigo está organizado de forma que a Seção 2 apresenta uma breve fundamentação. A Seção 3 apresenta os trabalhos relacionados. A Seção 4 descreve o

método proposto para o desenvolvimento do trabalho. A Seção 5 apresenta os testes experimentais e os resultados obtidos. Por fim, a Seção 6 aborda conclusões e trabalhos futuros.

2. Fundamentação

Esta seção apresenta a fundamentação para a modelagem utilizando-se dos modelos estocásticos markovianos.

2.1. Processos Estocásticos

Conforme Reichl [Reichl 2004] é necessário entender o conceito de processo estocástico e variáveis aleatórias para poder aplicar a Teoria das Probabilidades no mundo real. Um processo estocástico é uma sequência de variáveis aleatórias X_t , em que t pertence a um determinado conjunto temporal T . Os processos estocásticos usualmente são utilizados para descrever o funcionamento de um sistema que opera durante um determinado período de tempo e podem ser classificados em relação ao Estado (X_t) e em relação ao tempo T de forma contínua ou discreta.

2.1.1 Cadeias de Markov

Cadeias de Markov referem-se a processos estocásticos de estado e tempo discretos, e que exibem a propriedade markoviana representada na Equação 1:

$$P\{X_{t+1} = j \mid X_t = i\} = P\{X_{t+1} = j \mid X_t = i, X_{t-1} = i_1, X_{t-2} = i_2, \dots, X_0 = i_0\} \quad (1)$$

para $t = 0, 1, 2, \dots$ e toda sequência j, i, i_1, \dots, i_t , ou seja, espaço e tempo discretos.

A Equação 1 pode ser dita como a probabilidade de ocorrência do estado j no tempo $t+1$ está condicionada à ocorrência do estado i no tempo t , do estado i_1 no tempo $t-1$ e assim por diante, até o estado inicial.

As cadeias de Markov podem ser descritas por meio de uma matriz de transição. Considerando uma cadeia de Markov com N estados e p_{ij} a probabilidade de transição do estado i para o estado j , então a matriz $P = [p_{ij}]$ é denominada a matriz de transição desta cadeia de Markov, respeitando-se as seguintes propriedades:

- Ser uma matriz quadrada de dimensão $N \times N$, onde N é o número finito de estados do processo;
- $0 \leq p_{ij} \leq 1$, uma vez que p_{ij} representa uma probabilidade;
- A soma de cada linha da matriz de transição deve ser igual a 1, uma vez que os estados correspondem a eventos mutuamente exclusivos num estágio qualquer.

2.1.2 Modelos Escondidos de Markov

O Modelo Escondido de Markov (HMM – *Hidden Markov Models*) é o resultado da associação de uma cadeia de Markov com número finito de estados e um conjunto de densidades de probabilidade de evolução do sistema. Mesmo conhecendo os parâmetros do modelo não é possível determinar a evolução da cadeia de Markov para esse processo. A cadeia de Markov serve de suporte para o conjunto de observações associadas a um estado [Rabiner e Juang 1993].

O HMM permite a integração entre a modelagem estrutural e a modelagem probabilística. Para a modelagem dos atendimentos nas unidades de saúde de Curitiba

essa característica é importante, pois permite a entrada de sequências de observações O de tamanhos diversos, o que não se observa em outros classificadores. Por isso o termo ‘escondido’ ao modelo de Markov, pois não é possível saber quantas observações O_i correspondem a cada estado no modelo treinado. Este artigo não contempla em seu escopo a formulação teórica do HMM, porém uma introdução ao assunto pode ser encontrada em [Rabiner e Juang 1993].

Os modelos de HMM para a modelagem do perfil de atendimento nas unidades de saúde de Curitiba são baseados em uma abordagem global e uma topologia ergódica [Rabiner 1989], que corresponde a cada nó do modelo ser alcançado a partir de um outro nó qualquer por um número finito de passos.

Além do HMM integrar os diferentes níveis de modelagem, ele fornece algoritmos que determinam valores ideais para os parâmetros do modelo. Um modelo é representado por uma sequência de observações que devem ser estatisticamente independentes uma vez que a sequência oculta (*hidden*) de estado subjacente é conhecida. Deve-se primeiramente estabelecer uma estrutura para o modelo e a partir de então utilizar-se de estimativa de parâmetros para melhorar a probabilidade de geração de dados de treinamento por parte desses modelos. Durante a fase de treinamento o HMM absorve a sequência de observação, sendo capaz de associar cada estado de acordo com alguma função de densidade de probabilidade.

A formação do modelo baseia-se no algoritmo de *Baum-Welch* [Rabiner e Juang 1993]. Neste trabalho, o processo de classificação consiste em determinar a máxima probabilidade *a posteriori* para cada um dos registros de atendimento nas unidades de saúde de Curitiba, sendo que cada registro w gera uma sequência de observações O não conhecida pelo processo de treinamento. É válida a seguinte equação:

$$\Pr(\hat{w} | O) = \max_w \Pr(w | O) \quad (2)$$

Aplicando-se o teorema de Bayes, tem-se a equação fundamental de reconhecimento de padrões:

$$\Pr(w | O) = \frac{\Pr(O | w) \cdot \Pr(w)}{\Pr(O)} \quad (3)$$

Então, sabendo-se que $\Pr(O)$ não depende de w , a classificação torna-se equivalente a maximizar a probabilidade conjunta dada por:

$$\Pr(w, O) = \Pr(O | w) \cdot \Pr(w) \quad (4)$$

Deste modo, tem-se que $\Pr(w)$ é a probabilidade *a priori* do registro w e está relacionada com o problema modelado. Um modelo capaz de levar em consideração as variações dos registros w representados pelas sequências de observações O se faz necessário devido a estimativa de $\Pr(O|w)$. Durante os experimentos, o confronto dos *scores* entre cada modelo e as sequências de observações dos conjuntos de teste foi gerado pelo algoritmo de *Viterbi* [Rabiner e Juang 1993].

3. Trabalhos Relacionados

Na literatura há alguns trabalhos que se utilizam da categorização da população para promover melhor assistência médica à população idosa. Adamczyk [Adamczyk 2016] desenvolveu um sistema de monitoramento que se utiliza de informações da análise da respiração de pacientes idosos. O objetivo principal deste trabalho era desenvolver uma

classificação automatizada de eventos da Síndrome da Apneia Obstrutiva do Sono por meio do uso dos classificadores Rede Neural e SVM (*Support Vector Machine*). Os resultados obtidos não foram considerados satisfatórios, tendo suas taxas de acerto variando de 46,38% para o classificador Rede Neural e 49,77% para o classificador SVM.

Já no estudo de Sebestyen [Sebestyen et al. 2016] foram analisadas as possibilidades de implantar um sistema capaz de monitorar e reconhecer as atividades de uma pessoa idosa em sua casa, sem violar sua privacidade. Os dados foram coletados a partir de vários sensores e dispositivos móveis colocados na residência, com o intuito de inferir a sequência de atividades mais provavelmente realizada pelo idoso. Para o reconhecimento destas sequências foi utilizada o Modelo Escondido de Markov (HMM – *Hidden Markov Model*) em topologia sequencial. O objetivo principal do uso do HMM era informar a probabilidade do idoso estar desenvolvendo uma atividade e passar para outra. Essas probabilidades variaram entre 5% e 60%.

Chung e Liu [Chung e Liu 2008] fazem o uso do HMM para entender o comportamento de idosos em um centro de enfermagem de Taiwan por meio de imagens das câmeras de monitoramento. O objetivo do trabalho era reconhecer o comportamento dos idosos nos contextos espacial, de atividades desenvolvidas pelos idosos e também no contexto temporal. Esses contextos interagem entre si de forma que o contexto espacial era definido a partir da estrutura espacial, sendo o primeiro parâmetro a ser observado. As atividades eram observadas após o contexto espacial e a duração temporal observadas após as atividades. No trabalho, os comportamentos tidos como ‘anormais’ também foram levados em consideração. O HMM reconheceu a sequência de observações do comportamento dos idosos com uma taxa de acerto de 85%. Já o comportamento não trivial do idoso no centro de enfermagem foi reconhecido com uma taxa de 90%.

Os trabalhos de Adamczyk e Sebestyen, apesar de trabalhar com bases integralmente preenchidas, obtiveram taxas de classificação pouco expressivos. Já o trabalho de Chung e Liu obteve resultados mais próximo do esperado do HMM, apesar de trabalhar com bases integralmente preenchidas. Nosso desafio é trabalhar com bases parcialmente preenchidas e obter taxas de acerto acima de 90%, como no trabalho de Chung e Liu.

4. Proposta de Método para Modelagem do Perfil dos Pacientes

A proposta está baseada na definição dos modelos que representam o perfil dos idosos e dos demais pacientes atendidos nas unidades de saúde de Curitiba. A Figura 2 ilustra uma visão geral do método proposto.

Os esforços inicialmente se concentraram na obtenção da base de dados dos atendimentos das unidades de saúde de Curitiba. Obedecendo a Lei da Transparência¹, a Prefeitura Municipal de Curitiba disponibiliza na *Internet*, por meio do Portal de Dados Abertos da Prefeitura Municipal de Curitiba [Curitiba 2017], documentos, informações e dados governamentais de domínio público para a livre utilização pela sociedade,

¹ Lei Nº 12.527, de 18 de novembro de 2011.

garantindo à mesma, acesso aos dados primários, de forma que possam ser reutilizados produzindo novas informações e aplicações digitais para a sociedade. O Portal de Dados Abertos disponibiliza para *download* bases de dados dos diversos órgãos do Governo Municipal de Curitiba.

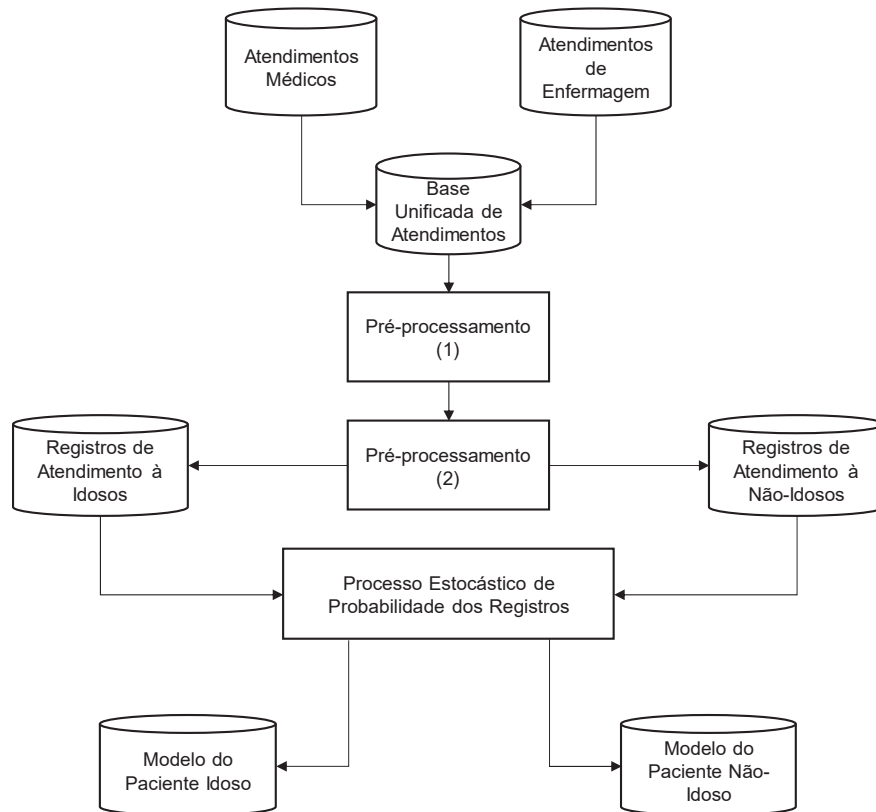


Figura 2 – Visão geral da proposta

Para o desenvolvimento deste trabalho foram utilizadas duas bases de dados referentes ao Sistema E-Saúde disponibilizadas no Portal de Dados Abertos da Prefeitura Municipal de Curitiba. Uma base contém o registro dos atendimentos médicos (AtMed) nas unidades de saúde de Curitiba e a outra os atendimentos de enfermagem (AtEnf). As bases são disponibilizadas mensalmente e contemplam o registro dos atendimentos dos três meses anteriores à sua publicação. Neste trabalho foi utilizada a base disponibilizada em Janeiro/2017, contemplando os atendimentos de Outubro à Dezembro/2016. As bases AtMed e AtEnf foram unificadas para o desenvolvimento do trabalho.

A Figura 3 mostra a distribuição desses registros segundo a faixa etária dos pacientes. Observa-se que cerca de 20% dos atendimentos mensais ocorridos nas unidades de saúde de Curitiba é voltado ao público idoso.




Figura 3 – Distribuição dos atendimentos das unidades de saúde de Curitiba separado por faixa etária

Para a modelagem e teste foram utilizados os 749.751 registros de atendimentos da base. Os campos de preenchimento de cada registro são apresentados na Tabela 1. Analisando as informações contidas na base observa-se que alguns campos são de preenchimento obrigatório, outros não. Também é possível observar a duplicidade de informações. Pode-se citar como exemplo os campos ‘Código do Tipo de Unidade’ e ‘Tipo de Unidade’. Esses campos estão correlacionados, ou seja, há apenas um código para cada tipo de unidade.

Tabela 1 – Campos de preenchimento dos registros de atendimento

CAMPOS DE PREENCHIMENTO DOS REGISTROS	
Data do Atendimento	Desencadeou Internamento
Data de Nascimento	Data do Internamento
Sexo	Estabelecimento Solicitante
Código do Tipo de Unidade	Estabelecimento Destino
Tipo de Unidade	CID do Internamento
Código da Unidade	Tratamento no Domicílio
Descrição da Unidade	Abastecimento
Código do Procedimento	Energia Elétrica
Descrição do Procedimento	Tipo de Habitação
Código do CBO	Destino Lixo
Descrição do CBO	Fezes/Urina
Código do CID	Cômodos
Descrição do CID	Em Caso de Doença
Solicitação de Exames	Grupo Comunitário
Qtde Prescrita Farmácia Curitiba	Meio de Comunicação
Qtde Dispensada Farmácia Curitiba	Meio de Transporte
Qtde de Medicamento Não Padronizado	Município
Encaminhamento para Atendimento Especialista	Bairro
Área de Atuação	

Um primeiro pré-processamento (Pré-processamento 1 da Figura 2) foi realizado eliminando as informações duplicadas da base. Além disso, algumas informações complementares foram acrescentadas à base, conforme as seguintes descrições:

- **Período de Atendimento:** com base na data e hora do atendimento, foi observado se o atendimento ocorreu no período da madrugada (0h às 6h), manhã (6h às 12h), tarde (12h às 18h) ou noite (18h às 0h).
- **Distrito Sanitário da unidade de atendimento e do bairro de moradia do paciente:** a cidade de Curitiba tem seu planejamento urbano dividido em dez distritos sanitários, cada um englobando alguns bairros de Curitiba e com diversas unidades de saúde. Foi identificado na base a qual distrito sanitário a unidade de saúde registrada no atendimento pertence, e a qual distrito sanitário o bairro de moradia do paciente pertence. Além disso, aumentou-se mais um campo na base com uma comparação entre esses dois distritos sanitários.
- **Capítulo do Código CID:** a Classificação Estatística Internacional de Doenças e Problemas Relacionados com a Saúde, também conhecida como CID (em inglês: *International Statistical Classification of Diseases and Related Health Problems*) fornece códigos relativos à classificação de doenças e de uma grande variedade de sinais, sintomas, aspectos anormais, queixas, circunstâncias sociais e causas externas para ferimentos ou doenças [CID 2017]. Esses códigos são divididos em 22 capítulos, cada um correspondente à algum tipo doença e/ou de sintoma. Com base na informação registrada no CID do atendimento, atribuiu-se o capítulo CID correspondente.

Finalizando esse primeiro pré-processamento, foram atribuídos valores para cada uma das informações contidas na base. Essa atribuição de valores se fez necessária pois o HMM, classificador utilizado neste trabalho, tem seu funcionamento aplicado a eventos discretos. Desta forma, após esse pré-processamento, os campos selecionados para a construção das bases de treinamento e testes são apresentados na Tabela 2.

Tabela 2 – Campos selecionados para a criação das bases de treinamento e teste

CAMPOS SELECIONADOS	
Período de Atendimento	Estabelecimento Destino
Sexo	Capítulo CID Internamento
Tipo de Unidade	Abastecimento
Descrição da Unidade	Energia Elétrica
Distrito Sanitário Unidade (DSU)	Tipo de Habitação
Descrição do Procedimento	Destino Lixo
Descrição do CBO	Fezes/Urina
Capítulo CID Atendimento	Meio de Comunicacao
Solicitação de Exames	Meio de Transporte
Encaminhamento para Atendimento Especialista	Município
Área de Atuação	Distrito Sanitário Bairro (DSB)
Desencadeou Internamento	Comparação DSU x DSB
Estabelecimento Solicitante	

Um segundo pré-processamento (Pré-processamento 2 da Figura 2) foi realizado separando os pacientes idosos dos demais pacientes. O objetivo desta identificação é trabalhar com cada tipo de paciente de forma independentemente, com o intuito de obter

os modelos do público idoso e dos não-idosos, sem que haja interferência entre esses modelos.

Os modelos de atendimento do público idoso e não-idoso foram definidos utilizando-se de técnicas que constituem os Modelos Escondidos de Markov (HMM – *Hidden Markov Models*). Com o HMM se pode obter a probabilidade de um determinado registro de atendimento pertencer ao modelo criado, mesmo esses registros não apresentando todas as informações no seu preenchimento.

Outra característica importante dos HMMs é que as observações são geradas independentemente para cada tipo de paciente, idoso e não-idoso, não havendo interdependência entre os elementos a serem modelados. Por exemplo, uma mesma base pode conter quantidades de registros diferentes para os tipos de paciente, com sequências de observações (equivalente ao vetor de atributos) de diferentes tamanhos. Os modelos treinados não necessitam ter a mesma quantidade de registro nos estados, mas devem possuir um número ideal de estados que permita a cada um desses absorver parte da sequência de observações O (Seção 2.1.2).

5. Testes Experimentais e Análise dos Resultados

Para a realização dos experimentos foram utilizados 749.751 registros de atendimentos, separando-os em registros de idosos e de não-idosos. As sequências de observações, provenientes de cada registro, tinham comprimento variando de 14 a 25 observações. Um total de 418 observações distintas poderiam compor essas sequências.

Para a modelagem do perfil de atendimento nas unidades de saúde de Curitiba foram utilizados os algoritmos HMM disponíveis no *toolkit* HTK [HTK 2017], considerando HMM discreto e topologia ergódica [Grundy 1997] [Szoke 2004]. As ferramentas do *toolkit* *HInit* e *HRest* foram utilizadas para o treinamento dos modelos. Essas ferramentas implementam o algoritmo de *Baum-Welch*. A ferramenta *HVite* do *toolkit* HTK, que implementa o algoritmo de *Viterbi*, foi utilizada para o teste dos modelos obtidos.

O treinamento para a obtenção dos modelos foi executado com *HInit* e *HRest* para as sequências de observação dos pacientes idosos e não-idosos, separadamente. O treinamento foi executado utilizando-se de 70% dos registros disponíveis (106.054 registros com sequências de observações de idosos e 418.772 registros com sequências de observações de não-idosos). A Tabela 3 mostra o número de estados HMM para os modelos treinados considerando cada conjunto de dados. Observa-se que os números de estados resultantes do treinamento são variáveis. Tal comportamento era esperado, comprovando que o procedimento de treinamento ajusta os modelos conforme às sequências de observações.

Tabela 3 - Número de estados resultantes do treinamento com HMM

	<i>IDOSO</i>	<i>NÃO-IDOSO</i>
Número de Estados	7	8

O *HVite* foi usado para testar os modelos obtidos, utilizando os outros 30% dos registros (45.452 registros com sequências de observações de idosos e 179.473 registros

com sequências de observações de não-idosos). Executando os testes de maneira tradicional, *all-against-all*, o *Z-score* apresentado nos resultados do *HVite* foi convertido para se obter as respectivas taxas de acerto [Grundy 1997]. Estes testes permitiram não somente verificar a eficácia do treinamento, mas também o grau de confusão (Tabela 4) entre os perfis do paciente idoso e do não-idoso, quando o modelo de um foi testado com o outro, de modo a constatar se observações distintas guardavam correlações intrínsecas entre os modelos obtidos.

A Tabela 4 apresenta, em forma de uma matriz de confusão, o resumo dos resultados obtidos. Pode-se observar pelo percentual de acerto que a separação dos modelos (idoso e não-idoso) não trouxe benefícios importantes, visto que os resultados são muito similares para ambos os casos.

Observando os resultados pode-se inferir que a base dos pacientes idosos, mais simples por ser composta por menos sequências de observação e menos estados HMM (Tabela 3) é equivalente à base dos pacientes não-idosos, mais complexo (com sequências e maior número de estados). Assim, a base dos pacientes idosos pode representar com vantagem à base dos demais pacientes por ser menos complexa.

Tabela 4 – Taxa de acerto média para os modelos testados

		<i>Modelo</i>	
		<i>IDOSO</i>	<i>NÃO-IDOSO</i>
<i>Teste</i>	<i>IDOSO</i>	97,17%	97,73%
	<i>NÃO-IDOSO</i>	97,42%	97,65%

No segundo experimento, os conjuntos de sequências de observações do paciente idoso e do não-idoso foram considerados combinados. Um total de 524.826 registros de observações foi utilizado para a criação do modelo e 224.925 registros foram utilizados para testar o modelo criado. Também de maneira tradicional, *all-against-all*, o *Z-score* apresentado nos resultados do *HVite* para os registros de teste foi convertido em percentual para se obter as respectivas taxas de acerto desses registros. Como resultado foi obtida uma taxa de acerto média de 97,36%.

Este experimento foi realizado com o objetivo de avaliar se a separação dos modelos (idoso e não-idoso) trazia benefícios à modelagem. Ao se aplicar os dados de entrada de idosos e não-idosos como um único conjunto, as taxas de acerto se mostram similares aos modelos em separado (Tabela 4). Deste modo, pode-se concluir que ao modelar o perfil do atendimento de idosos em separado é equivalente ao modelo combinado de todos os pacientes. A diferença está na complexidade do modelo combinado. Desta forma, é preferível a escolha do modelo de atendimentos à idosos.

Os experimentos mostram que se pode trabalhar apenas com um dos modelos, o do idosos, por exemplo, pois o objetivo deste trabalho é modelagem do perfil de atendimento deste público, e os resultados serão equivalentes a trabalhar com o modelo combinado.

6. Conclusão

Este artigo propôs um método para a modelagem do perfil de atendimento aos idosos nas unidades de saúde de Curitiba. Essa modelagem foi baseada nos registros de atendimentos separando-se as informações do público idoso do não-idoso.

Os experimentos realizados mostraram que o uso dos modelos do paciente idoso e do não-idoso fornecem resultados similares se considerados em separado ou combinados. Além disso, foi mostrado que há equivalência entre os registros de ambos os pacientes com suas sequências de observação. Desta forma, se pode trabalhar somente com os registros dos idosos, que aparecem em menor quantidade na base de dados.

Os resultados bastante expressivos de 97% de taxa de acerto só foram possíveis porque a HMM lida bem com a entrada desuniforme de sequências de observação, características destas bases de dados de saúde incompletamente preenchidas.

Entender como acontece o deslocamento do idoso até as unidades de saúde, usando o transporte público, é o que se pretende desenvolver como trabalhos futuros, de forma a contribuir com propostas que facilitem o atendimento a esse público, fazendo com que eles não precisem se deslocar mais que o necessário. Além disto, se o deslocamento for mais rápido, possivelmente os idosos vão aderir mais facilmente às campanhas de prevenção de doenças e vacinação da administração pública.

7. Referências

- Adamczyk, K.S. “Monitoring patient's condition based on breath detection”. Dissertação de Mestrado em Ciência da Computação - Norwegian University of Science and Technology, June 2016.
- Chung, P.; Liu, C. “A daily behavior enabled hidden Markov model for human behavior understanding”. *Pattern Recognition*, Volume 41, Issue 5, May 2008.
- Grundy, W. N. “Modeling Biological Sequences Using HTK”. Technical Report, 1997.
- HTK toolkit. Disponível em <<http://htk.eng.cam.ac.uk/>>. Acesso em 24 de março de 2017.
- IBGE - Portal do Instituto Brasileiro de Geografia e Estatística. Disponível em <<http://www.ibge.gov.br>>. Acessado pela última vez em 03 de dezembro de 2016.
- IPEA - Portal do Instituto de Pesquisa Econômica Aplicada. Disponível em <<http://www.ipea.gov.br>>. Acessado pela última vez em 03 de dezembro de 2016.
- Portal de Dados Abertos de Curitiba. Disponível em <<http://www.curitiba.pr.gov.br/dadosabertos/consulta/>>. Acessado pela última vez em 12 de janeiro de 2017.
- Portal da Classificação Estatística Internacional de Doenças e Problemas Relacionados com a Saúde. Disponível em <<http://www.cid10.com.br/>>. Acessado pela última vez em 22 de março de 2017.
- Rabiner, L.R.; Juang, B-H. “Fundamentals of speech recognition”. Prentice Hall Inc., Englewood Cliffs, New Jersey, 1993.

- Rabiner, L. R. "A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition". Proceedings of the IEEE, February, 1989. Vol. 77, No. 2, p.257-286.
- Reichl, L. E. "A Modern Course in Statistical Physics". WILEY-VCH, second edition, 2004.
- Sebestyen, G.; Stoica, I.; Hangan, A. "Human Activity Recognition and Monitoring for Elderly People". 12th International Conference on Intelligent Computer Communication and Processing, September 2016.
- Szoke, I. "Speech Units Automatically Generated by Ergodic Hidden Markov Model". Proceedings of 10th Conference and Competition Student EEICT, 2004. Vol. 1.