Universidade de São Paulo
Faculdade de Saúde Pública

Envelhecendo na cidade: Análises longitudinais do declínio da mobilidade e sobrevida de idosos com múltiplas estratégias

Carla Ferreira do Nascimento

Tese apresentada ao programa de pós-graduação em Saúde Pública da Faculdade de Saúde Pública da Universidade de São Paulo para obtenção do título de doutora em Ciências.

Área de concentração: Saúde Pública

Orientador: Prof. Dr. Alexandre Dias Porto
Chiavegatto Filho

São Paulo
2021

Envelhecendo na cidade: Análises longitudinais do declínio da mobilidade e sobrevida de idosos com múltiplas estratégias

Carla Ferreira do Nascimento

Tese apresentada ao programa de pós-graduação em Saúde Pública da Faculdade de Saúde Pública da Universidade de São Paulo para obtenção do título de doutora em Ciências.

Área de concentração: Saúde Pública

Orientador: Prof. Dr. Alexandre Dias Porto
Chiavegatto Filho

Versão revisada

São Paulo
2021

Autorizo a reprodução e divulgação total ou parcial deste trabalho, por qualquer meio convencional ou eletrônico, para fins de estudo e pesquisa, desde que citada a fonte.

Dedicatória

*Dedico esse trabalho aos meus avós, **Arli, Durval, Dinair e Severino** (in memorian), minha origem, meu orgulho e minha melhor memória de uma infância feliz.*

Agradecimentos

Aos meus pais, **Graça** e **Carlos**, por serem meus exemplos, minha base e minha rede de apoio, com quem sempre posso contar. À **Bruno**, pela paciência, parceria e compreensão, sem sua presença isso não seria possível. À **Kika**, minha inspiração de dedicação e determinação, e meu porto seguro quando morávamos em São Paulo. Aos meus filhos **Davi** e **Flora**, que, mesmo sem perceberem, me ensinam todos os dias e me fazem perceber que posso ser mais forte do que às vezes penso que sou.

Ao meu orientador, **Prof. Alexandre Chiavegatto Filho**, pela oportunidade, confiança, direcionamento e ensinamentos durante essa trajetória. Por ter me sempre me incentivado a pensar fora da caixa e ir além do óbvio, e ter me mostrado o quão incrível isso pode ser.

À **Profª. Yeda Duarte** pelos ensinamentos, disponibilidade dos dados, recursos oferecidos para tornar este trabalho viável, e contribuições dadas, junto ao **Prof. Jair Lício Santos**, na minha qualificação, bem como na brilhante condução do Estudo SABE.

Aos **Professores da Faculdade de Saúde Pública**, que através das disciplinas e reuniões científicas, me apresentaram ao “mundo da Epidemiologia”, e com os quais ainda pretendo aprender muito mais sobre essa ciência fascinante. Em especial ao **Prof. Francisco Chiaravalloti Neto**, com qual pude estar mais próxima durante o meu estágio PAE na disciplina de Epidemiologia Descritiva.

Aos **Funcionários da Faculdade de Saúde Pública**, em especial aos da secretaria do Programa de Saúde Pública, do Departamento de Epidemiologia, laboratório de informática e biblioteca, sempre solícitos.

À **Equipe do Estudo SABE**, em especial à **Clarissa Nazário**, pela colaboração nas demandas necessárias durante o processo do *linkage* entre os dados do SABE e do Sistema de Informação de Mortalidade (SIM), e aos **funcionários do Programa de Aprimoramento das**

Informações de Mortalidade (PRO-AIM), da Secretaria de Saúde do Município de São Paulo, que nos acolheu e ajudou durante esse processo.

Às **amigas e amigos** que encontrei nessa jornada e com os quais compartilhei alegrias, preocupações, conquistas, momentos de lazer e de muito trabalho. Em especial a **Hellen Geremias dos Santos**, pessoa brilhante com quem aprendi os primeiros passos da implementação de *machine learning*. À **Alejandra Roman Lay**, com quem dividi a tarefa de aprender e executar *linkage* de bancos de dados, e acabei descobrindo uma grande pessoa. E à **Maria Elizangela Junqueira**, sempre presente na “nossa salinha”, trocando experiências acadêmicas e de vida. Tenho saudades dos nossos cafezinhos! Falando em encontros, sou grata por ter encontrado no meu caminho a **Etienne Duim** e o **Alexandre da Silva**, que, desde o mestrado, sempre estiveram presentes, mesmo que nem sempre fisicamente.

Ao **André Filipe Batista**, com as suas contribuições diretas e indiretas, fundamental nessa reta final, e aos demais **membros do LABDAPS**. Com vocês aprendo dia-a-dia e lembro que, mesmo nesse momento de distanciamento social, a pós-graduação não precisa ser um processo solitário.

Por fim, ao **Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq)** pela bolsa concedida no período de outubro de 2016 a julho de 2018 (Processo nº 152494/2016-2).

Envelhecendo na cidade: Análises longitudinais do declínio da mobilidade e sobrevida de idosos com múltiplas estratégias

Resumo

Objetivo: Esta tese é apresentada no formato de quatro artigos científicos, que estão articulados em torno do objetivo geral, que foi analisar o declínio da mobilidade funcional e a mortalidade em idosos residentes no município de São Paulo. O primeiro artigo identificou os fatores associados ao declínio da mobilidade funcional em idosos ao longo de 15 anos de acompanhamento. O segundo analisou a sobrevida dos idosos por 10 anos de acordo com a mobilidade funcional por meio de regressões de Cox, tendo como desfecho o óbito por todas as causas e as principais causas específicas. O terceiro artigo testou a performance de algoritmos de *machine learning* na predição de óbito por causas específicas, utilizando como preditores testes de desempenho físico, variáveis de saúde e características sociodemográficas. O quarto artigo analisou a performance dos algoritmos de *machine learning* para prever declínio funcional em tarefas de mobilidade. **Métodos:** Os dados utilizados nas análises dos quatro artigos foram provenientes do Estudo Saúde, Bem-Estar e Envelhecimento (SABE), de múltiplas coortes e representativo para a população de residentes do município de São Paulo com idade igual ou superior a 60 anos. No primeiro artigo, foi realizada uma análise seriada de regressões multinível das quatro ondas do estudo, ocorridas em 2000, 2006, 2010 e 2015, com o objetivo de analisar a prevalência de limitação na mobilidade e as diferenças entre as ondas. Foram ajustadas, também, regressões logísticas separadas para cada onda, para analisar os fatores associados ao declínio da mobilidade. O segundo artigo utilizou regressões de Cox para analisar o tempo até o óbito por todas as causas e por causas específicas, de acordo com a condição de mobilidade, avaliada por dois testes (velocidade da marcha e o teste de levantar e sentar 5 vezes). Para o terceiro artigo, aprovado para publicação na revista *Age and Ageing*, foi realizada uma predição multinomial com cinco categorias: óbito por doenças do aparelho

circulatório, óbito por doenças do aparelho respiratório, óbito por neoplasias, óbito por outras causas específicas e não óbito. Algoritmos preditivos de *machine learning* foram treinados em 70% da amostra, e em seguida testados nos 30% restantes. No quarto artigo foram utilizados algoritmos de *machine learning* para prever a dificuldade na realização de tarefas de mobilidade, como caminhar, subir escadas, agachar e ajoelhar e carregar objetos. Nos dois últimos artigos, a capacidade preditiva dos modelos foi testada por meio da área abaixo da curva ROC, além de outras métricas como a sensibilidade e especificidade. **Resultados:** O primeiro artigo encontrou um aumento da prevalência de limitação na mobilidade após o ano 2000, mesmo após o ajuste por outros fatores. Foram também verificadas associações do declínio da mobilidade com condições crônicas de saúde e aspectos socioeconômicos. O segundo artigo identificou que o teste de levantar e sentar apresentou associação mais consistente com a mortalidade (HR=1.03, IC95% 1.00-1.05) do que a velocidade da marcha. Além disso, indivíduos com imobilidade apresentaram um risco aumentado de morrer por todas as causas (HR=1.71, IC95% 1.21-2.42) e por doenças do aparelho circulatório (HR=2.14, IC95% 1.25-3.65). No terceiro artigo, o desfecho em que os algoritmos apresentaram melhor poder preditivo foi a mortalidade por doenças do aparelho respiratório (AUC-ROC=0.89). Os algoritmos com melhor desempenho foram o *light gradient boosted machine* e *extreme gradient boosting*. No quarto artigo, o *random forest* foi o algoritmo com melhor performance e os desfechos com as melhores performances preditivas foram a dificuldade de agachar e ajoelhar (AUC-ROC: 0.81) e carregar pesos (AUC-ROC: 0.80). **Conclusão:** Os resultados da tese trazem novas evidências acerca do declínio da mobilidade funcional e mortalidade de pessoas idosas no Brasil. Além disso, demonstrou que algoritmos preditivos de *machine learning* podem ser ferramentas importantes para o rastreio de idosos em risco de desfechos negativos e o estabelecimento de medidas preventivas personalizadas.

Palavras-chaves: Envelhecimento populacional, limitação da mobilidade, mortalidade.

Aging in the city: Longitudinal analyses of the mobility decline and survival of older people with multiple strategies

Abstract

Objective: This thesis is presented in the format of four articles articulated around the general objective, which was to analyze the functional mobility decline and mortality in older residents from the municipality of São Paulo. The first article identified the associated factors of the decline in functional mobility in older adults over a 15-year follow-up. The second analyzed the 10-years mortality from all-cause and the main specific causes of death in older individuals according to functional mobility by Cox regression models. The third article tested the performance of machine learning algorithms in predicting death from specific causes, using physical performance tests, health and sociodemographic features as predictors. The fourth article analyzed the performance of machine learning algorithms to predict functional decline in mobility tasks. **Methods:** The data used in the four articles' analysis were from the Health, Well-Being, and Aging (SABE) Study, characterized by multiple cohorts and by a representative sample of the older residents from the municipality of São Paulo, aged 60 years and over. In the first article, we performed serial analysis of multilevel regressions of the four waves of the study, collected in 2000, 2006, 2010, and 2015, with the aim of analyzing the prevalence of limitation in mobility and the differences between the waves. Separate logistic regressions were also adjusted for each wave, to analyze the factors associated with the mobility decline. The second article used Cox regressions to analyze the time to all-cause and specific-cause of death, according to the mobility condition, assessed by two tests (gait speed and the 5 times chair stand test). For the third article, approved for publication in the journal *Age and Ageing*, a multinomial prediction was made with five categories: death from diseases of the circulatory system, death from diseases of the respiratory system, death from neoplasms, death from other specific causes and non-death. Predictive machine learning algorithms were trained

in 70% of the sample, and then tested in the remaining 30%. In the fourth article, machine learning algorithms were used to predict the difficulty in performing mobility tasks, such as walking, climbing stairs, crouching and kneeling and carrying objects. In the last two articles, the predictive performance of the models was tested using the area under ROC curve, in addition to other metrics, such as sensitivity and specificity. **Results:** The first article found an increase in the prevalence of mobility limitations after the year 2000, even after adjusting for other factors. Associations between the decline in mobility with chronic health conditions and socioeconomic aspects were also verified. The second article identified that the stand-up test presented a more consistent association with mortality (HR = 1.03, 95% CI 1.00-1.05) than gait speed. In addition, individuals with immobility had an increased risk of dying from all causes (HR = 1.71, 95% CI 1.21-2.42) and from diseases of the circulatory system (HR = 2.14, 95% CI 1.25-3.65). In the third article, the outcome which the best performance of the algorithms was mortality from diseases of the respiratory system (AUC-ROC = 0.89). The algorithms with best performance were the light gradient boosted machine and extreme gradient boosting. In the fourth article, the random forest presented the best performance and the outcomes with the best predictions were the difficulty of stooping, crouching or kneeling (AUC-ROC: 0.81) and carrying weights (AUC-ROC: 0.80). **Conclusion:** The results bring new evidence about the decline in functional mobility and mortality of older people in Brazil. In addition, it demonstrated that predictive machine learning algorithms could be important tools to screen older adults at risk of poor outcomes and could help to assign personalized preventive interventions.

Keywords: Population aging, mobility limitation, mortality.

Apresentação

Esta tese foi desenvolvida como resultado do doutorado no Programa de Pós-Graduação em Saúde Pública da Faculdade de Saúde Pública da Universidade de São Paulo, sob orientação do Prof. Dr. Alexandre Dias Porto Chiavegatto Filho. É apresentada na forma de coletânea de quatro artigos científicos e organizada em 5 seções: introdução, objetivos, métodos, resultados e discussão, e considerações finais.

Na introdução está apresentado o referencial teórico que fundamenta e justifica o tema da tese. Na seção seguinte são apresentados o objetivo geral e os específicos, sendo seguida pelos métodos gerais que caracterizam a amostra utilizada na tese, os dados do Estudo Saúde, Bem-Estar e Envelhecimento (SABE), que é representativa para a população de pessoas idosas residentes no município de São Paulo. Nessa seção também são descritos de forma breve os métodos específicos de cada artigo. Na seção de resultados e discussão estão apresentados os quatro artigos na íntegra, e, por fim, as considerações finais.

Para o desenvolvimento dos artigos, foram utilizadas diferentes estratégias de análise, sendo que no primeiro artigo apresentado, cujo título é “Mobilidade funcional autorreferida em idosos residentes no município de São Paulo, 2000-2015”, foram utilizadas modelos de regressão logística multinível para avaliar a mobilidade dos idosos de São Paulo ao longo de 15 anos. Para o segundo artigo, de título “*Functional mobility and 10-year all-cause and cause-specific mortality in older people from São Paulo, Brazil*”, foram realizadas análises de sobrevivência para avaliar a relação da mobilidade funcional com a mortalidade em idosos. No terceiro artigo (“*Cause-specific mortality prediction in older residents of São Paulo, Brazil: A machine learning approach*”), buscou-se avaliar modelos de *machine learning* na predição de óbito por causas específicas. Estratégia semelhante foi usada no quarto artigo (“*Early identification of older individuals at risk of mobility decline with machine learning*”), dessa vez

para prever a dificuldade na realização de tarefas específicas de mobilidade funcional em pessoas idosas.

O primeiro artigo está apresentado de forma inédita nesta tese, conforme normas do Programa de Pós-Graduação em Saúde Pública. O segundo e quarto artigo, até o momento do depósito desta tese, estão submetidos a periódicos e em fase de revisão por pareceristas. O terceiro artigo foi publicado na revista *Age and Ageing*, avaliada pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) com qualis A1.

As referências bibliográficas que compõem o corpo da tese, bem como apêndices e anexos estão apresentados no final do documento.

SUMÁRIO

1. INTRODUÇÃO	15
1.1 EPIDEMIOLOGIA DO ENVELHECIMENTO	16
1.2 O ENVELHECIMENTO EM ÁREAS URBANAS	19
1.3 DECLÍNIO FUNCIONAL NO ENVELHECIMENTO	20
1.4 MOBILIDADE FUNCIONAL NA PESSOA IDOSA	25
1.4.1 Mensuração da mobilidade	27
1.5 MOBILIDADE E MORTALIDADE EM IDOSOS	33
2 OBJETIVOS	35
2.1 OBJETIVO GERAL	35
2.2 OBJETIVOS ESPECÍFICOS	35
3 MÉTODOS	36
3.1 ESTUDO SABE (SAÚDE, BEM-ESTAR E ENVELHECIMENTO)	36
3.2 MÉTODO DO ARTIGO 1	40
3.3 MÉTODO DO ARTIGO 2	41
3.4 MÉTODO DO ARTIGO 3	42
3.5 MÉTODO DO ARTIGO 4	44
4 RESULTADOS E DISCUSSÃO	46
4.1 ARTIGO 1	47
4.2 ARTIGO 2	73
4.3 ARTIGO 3	102
4.4 ARTIGO 4	130
5 CONSIDERAÇÕES FINAIS	181
REFERÊNCIAS BIBLIOGRÁFICAS	183
APÊNDICE I	202
ANEXO I	203
ANEXO II	208
ANEXO III	209
ANEXO IV	210
CURRÍCULO LATTES	211

Siglas Utilizadas

AVC – Acidente Vascular Cerebral

ABVD – Atividades Básicas de Vida Diária

AIVD – Atividades Instrumentais de Vida Diária

CIF – Classificação Internacional de Funcionalidade, Incapacidade e Saúde

CID-10 – 10ª Edição da Classificação Internacional de Doenças

DATASUS – Departamento de Informática do Sistema Único de Saúde do Brasil

DCNT – Doenças Crônicas não Transmissíveis

ELSI-Brasil – Estudo Longitudinal de Saúde dos Idosos Brasileiros

FAPESP – Fundação de Amparo à Pesquisa do Estado de São Paulo

FSP/USP – Faculdade de Saúde Pública da Universidade de São Paulo

IMC – Índice de Massa Corpórea

LABDAPS – Laboratório de Big Data e Análise Preditiva em Saúde

OMS – Organização Mundial de Saúde

OPAS – Organização Pan-Americana de Saúde

PRO-AIM – Programa de Aprimoramento das Informações de Mortalidade no Município de São Paulo

SABE – Estudo Saúde, Bem Estar e Envelhecimento

SPPB – *Short Physical Performance Battery*

TUG – *Timed up and Go*

1. INTRODUÇÃO

Em nenhum momento da história a população viveu por tanto tempo como nos dias de hoje. A expectativa de vida da população mundial aumentou mais de 20 anos desde 1960 e esse processo continua, porém de forma desigual¹. Países mais desenvolvidos, como a França, já apresentam uma estrutura etária mais envelhecida, com 20% da população composta por pessoas de idade igual ou superior a 65 anos¹. Em outros países, como os que compõem a América Latina e Caribe, esse processo tem ocorrido de forma consideravelmente mais acelerada, com um aumento de 44% na proporção de idosos entre 1990 e 2010¹. Esse processo, que por si só já implica profundas mudanças individuais e sociais, é ainda mais desafiador em sociedades economicamente mais frágeis e com profundas desigualdades sociais como o Brasil².

Os anos adicionais vividos pode significar a possibilidade de novas oportunidades de convivência, novas experiências e de contribuição para as famílias, comunidades e sociedade como um todo³. No entanto, o incremento do tempo de vida da população nem sempre está acompanhado de uma expectativa de vida saudável, especialmente em países pobres ou em desenvolvimento^{2,4}. Eventos que ocorrem ao longo da vida, como as dificuldades no acesso aos serviços, a exposição a ambientes de risco e violentos, além do acúmulo de doenças crônicas, podem trazer impactos negativos para a saúde dos indivíduos, que são frequentemente evidenciados na velhice⁵⁻⁷.

Nesse cenário, a Organização Mundial de Saúde (OMS) tem promovido a década do envelhecimento saudável, que busca ampliar as contribuições das pessoas idosas para o desenvolvimento social, ajudando a evitar que essa rápida transformação demográfica se torne uma crise de assistência social e de saúde, sobretudo em países mais desiguais⁸. O conceito de envelhecimento saudável inclui basicamente três componentes: os ambientes com os quais as

peças interagem, a capacidade intrínseca, que inclui toda a capacidade física e mental de um indivíduo, e a habilidade funcional que combina os outros dois componentes, permitindo que o indivíduo tenha condição de atender as suas necessidades básicas, de aprender e tomar decisões, de se movimentar para realizar atividades e tarefas diárias, de se relacionar com outras pessoas e de contribuir para a sociedade^{8,9}.

A capacidade de se locomover é uma habilidade fundamental nesse processo por permitir a realização de atividades do dia-a-dia, o deslocamento para diferentes espaços, além de uma maior participação e engajamento social^{8,10}. Tal habilidade pode refletir tanto uma condição intrínseca ao indivíduo, quanto a presença de características ambientais e sociais que funcionam como barreiras ou facilitadores^{10,11}. Desse modo, a incapacidade nessas funções estaria relacionada aos problemas para superar e gerenciar as dificuldades na realização das tarefas.¹¹

A promoção do envelhecimento saudável requer uma melhor compreensão dos padrões de saúde e adoecimento da população que envelhece⁸. Assim, é fundamental o conhecimento do perfil de mobilidade funcional e aspectos relacionados, bem como o entendimento dos padrões de morbimortalidade levando em consideração a condição funcional da população idosa. Desse modo, é possível propor estratégias preventivas mais direcionadas e políticas públicas mais eficientes, que permitam intervenções individuais, ambientais, e também redução de desigualdades no acesso aos serviços de saúde e no atendimento às necessidades básicas.

1.1 EPIDEMIOLOGIA DO ENVELHECIMENTO

Um dos grandes marcos do século XXI tem sido o envelhecimento populacional. Pela primeira vez na história a maioria das pessoas passou a viver por 60 anos ou mais. Essa mudança

na distribuição etária da população está associada às reduções das taxas de natalidade e de mortalidade, impulsionadas pelo desenvolvimento social e econômico^{3,12}.

Mudanças no perfil de morbimortalidade da população decorrentes, principalmente, da queda na taxa de mortalidade infantil e na incidência de doenças infecciosas, têm influenciado nesse processo^{1,12-14}. Desde então, a expectativa de vida continuou crescendo e mais recentemente esteve associada, em grande parte, com a redução das taxas de mortalidade nas idades mais avançadas^{13,15}. No entanto, tal redução não ocorreu de maneira uniforme no mundo, sendo mais acentuada em países de renda mais alta, em parte por melhores condições na assistência à saúde e pela redução da exposição a fatores de risco¹⁵.

No Brasil, as mudanças mais evidentes relativas à transição demográfica começaram a partir da década de 70, quando ocorreram quedas acentuadas nas taxas de natalidade e mortalidade¹⁶. Nesse período, a proporção de pessoas com idade igual ou superior a 60 anos era de 5,2%, e passou a representar 10,8%, de acordo com o último censo de 2010^{16,17}. Assim como observado em estudos internacionais, o envelhecimento populacional não foi uniforme em todo o país, sendo mais tardio em regiões com maior desvantagem socioeconômica^{4,18}. Em 2010, o índice de envelhecimento, ou seja, o número de pessoas com idade a partir de 60 anos para cada 100 pessoas menores de 15 anos, era de cerca de 55% nas regiões Sul e Sudeste, e de menos de 39% nas demais regiões¹⁶.

Em 2019, as principais causas de óbito entre brasileiros com 60 anos e mais foram as doenças crônicas não transmissíveis (DCNT), mais especificamente as neoplasias malignas, as doenças isquêmicas do coração e as doenças cerebrovasculares¹⁹. No município de São Paulo, as doenças do aparelho circulatório, capítulo IX da Classificação Internacional de Doenças (CID-10), que inclui, entre outras causas, as doenças isquêmicas do coração e as cerebrovasculares, representavam apenas 12% de todas as causas de óbito na década de 30²⁰. De acordo com os dados mais recentes do Departamento de Informática do Sistema Único de

Saúde do Brasil (DATASUS), esse percentual passou a ser de 31%, seguido pelas neoplasias com 20%, e as doenças do aparelho respiratório com cerca de 14%¹⁹. Essa transição epidemiológica é uma tendência mundial e está fortemente relacionada ao envelhecimento populacional, bem como às condições socioeconômicas e sanitárias^{4,18}.

É importante mencionar, que a idade média do surgimento dessas doenças, assim como a sobrevida na presença delas vem aumentando, principalmente em regiões com maior renda⁴. Se por um lado isso reduz a mortalidade geral, por outro gera um aumento do tempo vivido com incapacidade e com necessidades de cuidado e reabilitação^{4,21}. Outra consequência dessa redução da mortalidade numa população mais envelhecida é a sobreposição de condições crônicas, ou a presença mais prevalente da multimorbidade²². Dados do Estudo Longitudinal de Saúde dos Idosos Brasileiros (ELSI-Brasil), apontam que 63% das pessoas com 60 anos ou mais residentes no Brasil convivem com 2 ou mais DCNT²³. Na cidade de Bagé, em 2008, esse percentual foi de 81%²⁴, e em São Paulo, 2010, correspondeu a 59%²⁵.

A multimorbidade está associada ao aumento dos gastos com saúde²³ e é um importante fator de risco para hospitalização, morte e declínio funcional entre idosos^{24,26,27}. Nesse cenário, além das DCNT já mencionadas, outras condições surgem como importantes causas de incapacidades, como a diabetes, a dor lombar, as quedas, as deficiências visuais e as demências⁴.

Nesse cenário é importante considerar os dados atuais referentes à pandemia pelo novo coronavírus, que já apontam uma interrupção do crescimento da expectativa de vida, que vinha ocorrendo de forma contínua²⁸⁻³⁰. Sabe-se que as faixas etárias avançadas são as mais atingidas³¹ e que a presença de DCNT está associada com formas mais graves da doença, bem como maior risco de óbito ou de sequelas. Embora ainda existam muitas incertezas acerca do real impacto da pandemia no processo de transição epidemiológica e demográfica, é esperado que as demandas por cuidados de saúde, sobretudo entre adultos idosos, aumente de forma

considerável^{32,33}. Além disso, é possível que as disparidades sociais nos processos de saúde e doença se tornem mais evidentes^{28,30}.

1.2 O ENVELHECIMENTO EM ÁREAS URBANAS

Outro importante marco do século XXI tem sido a urbanização. Em 2008, pela primeira vez, a maior parte da população mundial passou a viver em cidades em vez de zonas rurais³⁴, sendo que no Brasil, essa marca foi alcançada mais precocemente, por volta da década de 70³⁵. Estimativas apontam que, em 2050, 25% da população urbana de países em desenvolvimento será composta por idosos. Por um lado isso pode facilitar o acesso a serviços e recursos que são mais difíceis em regiões menos populosas, mas por outro lado, as cidades foram construídas numa lógica voltada para uma população relativamente jovem e ativa³⁶.

Vários motivos podem tornar as pessoas idosas mais vulneráveis aos problemas característicos dos centros urbanos, como a violência, problemas arquitetônicos e de mobilidade urbana, e perda das redes de apoio social^{34,36}. Um desses motivos é o fato de que o tempo de exposição em geral é maior, pelo próprio tempo de vida, ou mesmo pelo padrão de uso do espaço. Diferentemente dos jovens, que em geral se expõem a diversos contextos diferentes, como o trabalho, o lazer e outras relações sociais, as pessoas idosas tendem a permanecer mais tempo no seu local de residência³⁷. Além disso, frequentemente têm a rede de apoio social reduzida pelas mortes dos amigos e cônjuges e pela mudança dos parentes mais jovens. Tudo isso somado ao fato de que o envelhecimento aumenta o risco de declínio funcional e cognitivo, faz com que o impacto dos problemas contextuais e das barreiras ambientais seja exacerbado nesse grupo populacional³⁷.

Essa realidade tem sido objeto de estudo e motivou o desenvolvimento de diretrizes para transformar espaços urbanos em ambientes amigáveis ao envelhecimento, o “*Global Age-friendly Cities: A Guide*”, publicado pela OMS³⁸. De acordo com esta publicação, uma cidade amigável facilitaria um envelhecimento ativo, no qual as oportunidades de saúde, participação social, segurança e qualidade de vida seriam otimizadas na medida em que as pessoas envelheceriam^{38,39}. Embora a adesão ao programa seja crescente desde a sua primeira implementação, não é a realidade em grande parte dos centros urbanos⁴⁰.

O Brasil é considerado o país mais urbanizado da América Latina. Nele, o município de São Paulo é o mais populoso, com 11.253.503 residentes, dos quais 12% tem idade igual ou maior que 60 anos¹⁷. Esse município, que também é considerado o maior centro urbano da América do Sul, teve um crescimento de 88% na população de pessoas idosas entre 1980 e 2010¹⁷. Dadas essas características, o rápido processo de envelhecimento da população, e as profundas desigualdades sociais⁴¹, o Município de São Paulo foi incluído, junto com mais seis centros urbanos da América Latina e Caribe, num projeto que buscou compreender as condições de vida da população idosa dessa região e, assim, projetar as necessidades de saúde resultantes do rápido envelhecimento populacional⁴². Este projeto, conhecido como Estudo Saúde, Bem Estar e Envelhecimento (SABE), teve seu primeiro inquérito no ano 2000, sob coordenação da Organização Pan-Americana de Saúde, e desde então vem apontando resultados importantes no que diz respeito à situação de saúde, aspectos socioeconômicos e no acesso à serviços da população idosa residente neste município⁴²⁻⁴⁴.

1.3 DECLÍNIO FUNCIONAL NO ENVELHECIMENTO

De acordo com a Classificação Internacional de Funcionalidade, Incapacidade e Saúde (CIF) o termo funcionalidade se refere a todas as funções dos sistemas e estruturas do corpo, às atividades e à participação social¹⁰. Assim, uma incapacidade seria resultante da interação entre alguma disfunção apresentada pelo indivíduo com as barreiras ou facilitadores ambientais, que levariam a limitações na realização de atividades e restrição na participação social. Assim, a condição funcional de um sujeito não seria consequência apenas do estado de saúde ou presença de doenças, mas também de aspectos contextuais, como o ambiente físico e social, aspectos culturais, disponibilidade e acesso a serviços¹⁰. A Figura 1 apresenta o modelo conceitual da CIF e evidencia as relações de mão dupla entre todos os componentes (estrutura do corpo, atividade e participação), com o estado de saúde e os aspectos contextuais¹⁰.

Figura 1: Interação entre os componentes da CIF. Fonte: OMS, 2015.

Outros modelos conceituais também buscam explicar a saúde, considerando as complexas relações entre os aspectos individuais e o contexto. Dahlgren e Whitehead, em 1991, apresentaram um modelo que buscou explicar as desigualdades sociais em saúde, com o objetivo de buscar e propor estratégias para aumentar a equidade entre os diferentes grupos sociais e ocupacionais⁵. De acordo com esse modelo, a saúde dos indivíduos seria consequência das interações entre os diferentes níveis contextuais, como as condições socioeconômicas, ambientais e culturais, as condições de vida e de trabalho, as relações interpessoais e comunitárias e o estilo de vida, com os aspectos individuais, os quais se tem pouco ou nenhum controle, como a idade, o sexo e os aspectos genéticos⁵.

Outras abordagens epidemiológicas também têm considerado a saúde de uma forma multifatorial e decorrente de uma interação do indivíduo com o meio. Assim, pesquisadores têm tentado compreender os efeitos da exposição a certos fatores de risco, comportamentos, ambientes e contexto socioeconômico ao longo da vida^{7,45}. Essa linha de estudo é conhecida por epidemiologia de curso de vida e tem sido utilizada na gerontologia para se buscar entender a influência de aspectos da trajetória de vida na condição funcional de pessoas idosas^{7,46}.

É importante observar que independente do modelo explicativo, o processo de saúde e funcionalidade tem sido entendido como resultado de complexas interações entre fatores individuais, ambientais e socioeconômicos ao longo da vida, estando alinhado com a ideia de Envelhecimento Saudável, defendida pela OMS^{8,47}. O Relatório Mundial de Envelhecimento e Saúde, 2015, conceitua o envelhecimento saudável como “o processo de desenvolvimento e manutenção da capacidade funcional que permite o bem-estar em idade avançada”⁴⁷. Essa capacidade funcional dependerá da capacidade intrínseca e também das características ambientais e das interações sociais, que podem se caracterizar como facilitadores ou barreiras à participação social. Além disso, a capacidade funcional pode se modificar ao longo do tempo,

a depender, por exemplo, de intervenções ou escolhas individuais, determinando as trajetórias de cada indivíduo⁴⁷.

Do ponto de vista biológico, o envelhecimento está associado a um processo de perda das reservas fisiológicas, devido ao acúmulo gradual de danos moleculares e celulares. Isso leva ao aumento do risco de adquirir doenças e favorece um declínio geral na capacidade intrínseca^{47,48}. Embora aspectos genéticos influenciem no processo de envelhecimento, a variabilidade das funções orgânicas e sistêmicas tende a aumentar com a idade, como mostra estudos de epigenética com gêmeos idênticos, sugerindo que o ambiente e eventos no curso da vida apresentam importante papel nas trajetórias de funcionalidade dos indivíduos⁴⁹.

Um envelhecimento saudável é associado a maior independência funcional e autonomia, além de capacidade para se adaptar às condições adversas e criar estratégias para compensar os comprometimentos decorrentes do avançar da idade⁴⁸. Pessoas idosas com alterações intrínsecas, que as tornam biologicamente mais vulneráveis e com grandes dificuldades adaptativas, apresentam fragilidade, e estão sujeitas ao declínio mais acelerado da capacidade funcional^{48,50,51}. Uma recente metanálise estimou que 24% das pessoas idosas brasileiras apresentam fragilidade⁵². Embora fragilidade não seja sinônimo de incapacidade, os dois conceitos estão fortemente associados^{53,54}. Resultados do Estudo ELSI-Brasil mostraram que entre os indivíduos considerados frágeis, 45% tinha limitação em atividades básicas de vida diária (ABVD)⁵³. Entre americanos com idade igual ou maior do que 65 anos e com dificuldades nas ABVD, 27,5% foi considerado frágil, de acordo com os resultados descritos por Fried e colaboradores, em 2001⁵⁴.

O declínio funcional pode surgir de forma catastrófica, como nos casos de fraturas, ou de maneira gradual, como nos casos das condições crônicas⁴⁸. A tendência é que o processo ocorra numa lógica hierárquica, na qual as atividades instrumentais de vida diária (AIVD) são comprometidas primeiro, e em seguida, as ABVD⁴⁸. As ABVD incluem aquelas relacionadas

ao autocuidado, como tomar banho, usar o banheiro, se alimentar, se vestir, e se transferir⁵⁵. As AIVD envolvem tarefas mais complexas, mais seletivas, que requerem um controle mais harmônico de várias funções simultâneas⁴⁸. Estão mais relacionadas ao convívio social, incluindo a habilidade para usar meios de transporte, telefonar, preparar refeições, fazer compras, manejar o próprio dinheiro, cuidar da casa e cuidar da própria medicação⁵⁶.

Resultados da primeira onda do Estudo SABE, em 2000, mostraram que 30,1% dos idosos que residiam no Município de São Paulo apresentavam alguma dificuldade na execução das AIVD⁵⁷. Entre aqueles que não apresentavam incapacidade nas AIVD em 2000, a incidência na onda seguinte foi de 35,6 por 1000 pessoas/ano⁵⁸. Já para incidência de limitação nas ABVD esse valor foi de 31/1000⁵⁹. Ainda de acordo com os resultados desse estudo, foi observado uma tendência hierárquica de comprometimento, em que atividades básicas mais complexas como se vestir apresentaram maior incidência de comprometimento, seguidas pelas transferências, tomar banho, e por último, se alimentar⁵⁹.

Esses resultados sugerem que o início de um processo de declínio funcional poderia ser observado por queixas de dificuldades em atividades como o ato de se vestir, que requer uma boa função muscular dos membros superiores e inferiores, flexibilidade, coordenação fina, e controle postural. Em estágios mais avançados, tarefas como o ato de se alimentar, que normalmente é realizado na posição sentada, seriam afetadas⁵⁹. Lógica similar é observada no processo de declínio funcional nas AIVD, em que inicialmente tende a ocorrer limitação para uso de meios de transporte e, num estágio mais avançado, para cuidar do próprio dinheiro ou tomar os remédios⁵⁸. Esse processo de declínio costuma ser diferente entre homens e mulheres e está associado a aspectos sociais e ligados à saúde individual, como estado cognitivo, presença de doenças crônicas, depressão, história de quedas, prática de atividade física e performance física^{58,59}.

1.4 MOBILIDADE FUNCIONAL NA PESSOA IDOSA

Um aspecto extremamente importante para a manutenção da funcionalidade e independência em grande parte das atividades de vida diária é a mobilidade funcional⁶⁰. Essa habilidade pode ser definida como a capacidade de se locomover de forma independente e segura de um local para o outro, e envolve muitas tarefas como as transferências para ficar de pé, deambulação, correr, pular, dirigir e usar transporte público⁶¹.

De acordo com a CIF, a mobilidade é um dos domínios relacionados com as atividades e participação dos indivíduos, e inclui a mudança da posição do corpo, carregar, mover ou manipular objetos, andar, correr, escalar, e utilizar várias formas de transporte¹⁰. Dessa forma, o declínio da mobilidade pode ser considerado uma grande desvantagem no processo do envelhecimento, uma vez que limita não somente as atividades rotineiras, mas também a produtividade e o engajamento social⁶². A mobilidade no entorno, a forma como o indivíduo se locomove e explora a sua comunidade, se relaciona e socializa, conceito conhecido como *life-space mobility*, é, portanto, um aspecto importante para a saúde e qualidade de vida das pessoas idosas⁶³.

É importante considerar que o declínio da mobilidade não se relaciona apenas ao avançar da idade, mas também com outros aspectos do curso de vida, que incluem comportamentos e hábitos, aspectos ambientais e relações sociais com a comunidade e família⁶⁴. O comprometimento da mobilidade, então, estará presente quando a capacidade de compensar os efeitos cumulativos das alterações funcionais não forem mais suficientes para conduzir as tarefas do dia-a-dia^{64,65}. Do ponto de vista intrínseco, tanto alterações fisiológicas do envelhecimento, quanto a presença de doenças ou outras condições adversas, que se instalem

de forma súbita ou gradual, podem afetar a capacidade adaptativa necessária para manter a independência nas tarefas relacionadas à locomoção⁶⁵.

Uma mobilidade adequada requer funcionamento conjunto de diferentes sistemas corporais, que permitam um controle postural adequado, além de progressão, garantida por padrões de ativação muscular que promovem o deslocamento do corpo na direção desejada, e adaptação às exigências ambientais⁶⁶. Para isso, é necessário um sistema nervoso íntegro, com informações sensoriais sendo captadas e integradas, respostas motoras antecipatórias ou reativas eficientes, bem como uma função cognitiva preservada⁶⁶. Força muscular, flexibilidade e amplitudes articulares também são essenciais na manutenção da função da mobilidade⁶⁷.

O processo do envelhecimento leva à perda progressiva do funcionamento dos diversos sistemas corporais⁶⁸⁻⁷⁰. A sarcopenia, conhecida como a perda da força e da qualidade da massa muscular relacionada à idade, é um aspecto que está associado à imobilidade⁷¹. Pode ocorrer como consequência da inatividade física causada pela perda da mobilidade, mas também pode acentuar o declínio na mobilidade funcional, ou aumentar o risco de eventos adversos na presença concomitante com a imobilidade^{70,72,73}. No entanto, a perda de função muscular isolada não justifica o comprometimento da capacidade de se locomover, o que aconteceria apenas em níveis mais críticos de fraqueza muscular⁶⁴. Evidências sugerem que a força muscular é mais importante para a predição de declínio da mobilidade na presença de um equilíbrio já comprometido^{64,74}. Além disso, alguns grupos musculares parecem estar mais relacionados com esse desfecho, como os músculos responsáveis pela flexão dorsal dos tornozelos, do que outros, como a força de preensão palmar, mais utilizada em estudos dessa natureza⁷⁵.

Alterações sensoriais, como as deficiências auditivas, vestibulares, visuais e somatossensitivas, também estão relacionadas com a limitação na mobilidade^{66,68}. Perdas nessas funções estão relacionadas à idade e também podem ocorrer como consequência da

instalação de doenças, como acidente vascular cerebral (AVC) e diabetes. Dificuldades em integrar essas informações comprometem o controle adaptativo dos movimentos. Por exemplo, as informações visuais permitem que pessoas se antecipem a presença de obstáculos ou outros riscos ambientais. Já informações somatossensitivas, relacionadas à inclinação ou textura do solo, permitem que os indivíduos ajustem os movimentos ou recuperem uma situação de desequilíbrio⁶⁶.

Pessoas com a audição comprometida apresentam dificuldade em dividir a atenção entre as diferentes demandas do ambiente, como ruído do tráfego e discussões, com as outras demandas necessárias ao controle postural⁶⁵. Isso aumenta o risco de queda, limita a realização de atividades em ambientes externos, favorecendo um declínio funcional mais acentuado⁶⁵. Nesse sentido, é importante ressaltar a importância do sistema cognitivo⁷⁶, que, entre as suas funções, permite que um indivíduo seja capaz de organizar os padrões de movimento direcionados a um certo objetivo, papel conhecido como planejamento motor⁷⁷. Além disso, também permite que a atenção seja dividida entre diferentes demandas^{66,67,76}, como ocorre, por exemplo, quando se conversa ao caminhar.

1.4.1 Mensuração da mobilidade

Como já mencionado, as tarefas de mobilidade incluem desde mudanças posturais até atividades de locomoção. Diferentes métodos de mensuração da mobilidade têm sido descritos e utilizados na literatura, envolvendo tanto questões autorrelatadas, quanto testes de performance física⁶⁷.

- *Velocidade da marcha*

A marcha humana é um dos aspectos da mobilidade mais estudados. É caracterizada por movimentos cíclicos e sincronizados que deslocam o corpo à frente sem que haja perda do equilíbrio. Diversas alterações nesse ciclo ocorrem em função do envelhecimento, como redução do comprimento do passo, aumento da base de suporte, redução da velocidade, das amplitudes de movimento articulares do quadril, joelho e tornozelo, e até nas oscilações dos membros superiores⁶⁶. Nesse contexto, a velocidade da marcha é um recurso simples e barato, porém importante, de avaliação do idoso, que se relaciona com diferentes desfechos, como incapacidade, quedas e mortalidade⁷⁸⁻⁸⁰. Alguns autores o consideram tão valioso, que definem a velocidade da marcha como o “sexto sinal vital”^{81,82}.

A mensuração da velocidade da marcha pode ser obtida por diferentes métodos. Uma das mais importantes diferenças observadas na literatura é a distância na qual o teste será realizado, que pode variar de 2 a 40 metros, a depender do estudo⁸³. Outras diferenças incluem a consideração das fases de aceleração e desaceleração no início e fim do percurso, se a caminhada é em linha reta ou envolve mudanças de direção, como girar e retornar, as instruções dadas e até o dispositivo usado para a marcação do tempo⁸². Embora as distâncias maiores e com início e fim dinâmicos (considerando a fase de aceleração e desaceleração) sejam mais sensíveis na detecção de alterações funcionais, o uso de distâncias menores é recomendado quando não se dispõe de espaço suficiente^{82,84}.

Uma velocidade da marcha reduzida é considerada preditora para eventos adversos em pessoas idosas, como incapacidade funcional⁷⁸, institucionalização⁷⁹, quedas⁸⁵ e óbito^{86,87}. Além disso, está associada a desvantagens sociais e na saúde individual. Num estudo conduzido com uma amostra representativa de idosos do município de São Paulo, em 2010, a velocidade da marcha reduzida se associou com nível de escolaridade mais baixo, presença de dificuldades nas AIVD, inatividade física e presença de doenças cardiovasculares⁸⁸. Outro estudo com essa mesma população, demonstrou que quase todos os participantes (97,8%) não apresentavam

velocidade de marcha mínima para atravessar as ruas dentro do tempo padronizado nos semáforos⁸⁹. Isso demonstra que a velocidade da marcha reduzida é também um aspecto que dificulta a independência na realização de atividades externas e a participação social de pessoas idosas, sobretudo na existência de ambientes desfavoráveis^{67,89}.

- *Mudanças posturais e o teste de levantar da cadeira*

As mudanças posturais são essenciais para independência em ABVD, incluem as passagens de deitado para sentado e para de pé, o ato de rolar na cama e as transferências de sentado para de pé. Esta última é considerada um pré-requisito para a marcha, de modo que idosos incapazes de executá-la acabam permanecendo mais tempo sentados, mesmo quando seriam capazes de andar⁶⁷.

Para um indivíduo se levantar de uma cadeira ele precisa passar por quatro etapas básicas, que são (1) a inclinação do tronco para frente, (2) o deslocamento vertical, que inclui a elevação do corpo e o afastamento do quadril do assento, (3) a extensão dos quadris e joelhos, e por fim, (4) o movimento do tronco para trás e a extensão completa do corpo^{90,91}. Para que todas essas etapas ocorram, é necessário que os múltiplos sistemas envolvidos com a mobilidade humana, já mencionados anteriormente, estejam trabalhando mutuamente⁶⁶. Ressalta-se a importância da força muscular dos membros inferiores e tronco, as amplitudes de movimento, sobretudo em quadris, joelhos e tornozelos, além de estratégias de equilíbrio preservadas^{66,90,91}.

Em geral, pessoas idosas, mesmo saudáveis, tendem a realizar essa tarefa em maior tempo do que adultos jovens⁶⁶, porém se apresentarem alterações no equilíbrio esse tempo pode ser ainda maior⁹². O tempo necessário para levantar uma ou mais vezes de uma cadeira, ou a quantidade de vezes que se consegue levantar e sentar num determinado tempo, podem ser usados para mensurar a força muscular dos membros inferiores, a mobilidade e o equilíbrio em

pessoas idosas^{92,93}. O teste de levantar e sentar 5 vezes tem sido utilizado para rastreio de fragilidade em idosos⁹⁴, sendo considerado um preditor de incapacidade^{93,95} e quedas⁹³.

- *Outras medidas físicas de mobilidade*

O *Timed up and Go* (TUG) é também uma ferramenta amplamente usada para avaliação da mobilidade em idosos, e consiste no tempo gasto para levantar de uma cadeira, caminhar 3 metros, fazer a volta, retornar e sentar novamente na mesma cadeira^{96,97}. Em idosos brasileiros, um tempo maior ou igual a 12,47s está associado a maior risco de quedas⁹⁷ e, em uma amostra representativa de idosos residentes no município de São Paulo, se associou a piores níveis de escolaridade²⁵. Nessa mesma população, observou-se que tempos maiores no TUG estão associados a quedas em ambientes internos⁹⁸.

A *Short Physical Performance Battery* (SPPB) é um instrumento composto por três testes que avaliam o equilíbrio em pé, a velocidade de marcha em passo habitual e a força muscular de membros inferiores. Nessa bateria de testes a velocidade da marcha pode ser medida através de uma distância de 3 ou 4 metros, e a força dos membros inferiores, pelo teste de sentar e levantar 5 vezes. Para cada teste pode-se pontuar de 0 a 4 pontos, de modo que o escore final obtido pode chegar a 12 pontos⁹⁹. É um preditor para mortalidade em idosos¹⁰⁰ e, além disso, está associado com a saúde autoavaliada, a presença de doenças crônicas e dificuldades nas atividades de vida diária¹⁰¹.

Outras escalas de avaliação também têm sido usadas na mensuração da mobilidade, como a POMA (*Performance-oriented mobility assessment*), que é composta de 13 tarefas relacionadas ao equilíbrio e nove tarefas relacionadas à mobilidade na marcha¹⁰², e a Escala de Berg, que originalmente foi desenvolvida para avaliar o equilíbrio, mas que pode ser uma boa ferramenta para predição de incapacidade na mobilidade^{67,103}.

- *Mobilidade autorreferida*

Além de testes de performance física, a mobilidade autorreferida também se mostra uma importante ferramenta para a avaliação funcional de idosos. Além de maior facilidade na obtenção, sobretudo em inquéritos populacionais, podem capturar aspectos do bem-estar e saúde individuais, que não são identificados em testes clínicos, sendo também reconhecidos como importantes preditores de sobrevida em pessoas idosas¹⁰⁴⁻¹⁰⁶.

Existem diferentes métodos de mensuração da mobilidade através do autorrelato, de modo que importantes variações nas prevalências de incapacidade são encontradas na literatura^{106,107}. Essas variações podem ser decorrentes do tipo de pergunta realizada, das categorias de respostas disponíveis e até mesmo do fato de ter sido autorrespondido ou respondido para um entrevistador¹⁰⁶.

Perguntas sobre a existência de dificuldade em caminhar um ou mais blocos, levantar de uma cadeira após longo período sentado, subir escadas, carregar pesos ou sacolas, ajoelhar ou agachar, são amplamente utilizadas em estudos sobre mobilidade, e estão associados ao risco aumentado de desfechos adversos em idosos^{106,108,109}. Estudos também evidenciam que, assim como as ABVD e AIVD, essas tarefas apresentam uma tendência hierárquica de declínio dentro do processo do envelhecimento¹⁰⁸. Desse modo, a capacidade de agachar e ajoelhar e de subir escadas seria uma das tarefas com maior incidência de dificuldade e que seriam primeiro comprometidas, indicando o início de um processo de declínio funcional¹⁰⁸.

Dados brasileiros de 1998 já mostravam que a maior parte dos idosos apresentava alguma dificuldade autorreferida em tarefas de mobilidade. Entre os homens a prevalência era de quase 70% e, entre as mulheres, mais de 80%¹¹⁰. Os itens analisados incluíam alimentar-se, tomar banho ou ir ao banheiro; correr, levantar peso, praticar esportes ou realizar trabalhos pesados; empurrar uma mesa ou fazer trabalhos domésticos; subir degraus; ajoelhar-se ou abaixar-se; caminhar mais de 1 km; e caminhar aproximadamente 100 metros¹¹⁰. Entre esses

itens, aqueles como maior prevalência foram correr, levantar peso, praticar esportes ou realizar trabalhos pesados, e em seguida, a dificuldade em subir escadas¹¹⁰.

Um outro estudo nacional, demonstrou que 22,6% dos idosos brasileiros relatava alguma dificuldade para caminhar uma distância de 100 metros. Essa prevalência era maior entre as mulheres e entre as faixas etárias mais avançadas, e variava entre as regiões do país¹⁰⁷, demonstrando ser um aspecto associado a fatores sociodemográficos, além das características de saúde individuais, como em outras populações^{106,111–113}. Resultados de uma análise conduzida em idosos do município de São Paulo, também mostrou que a presença de dor crônica é um importante fator associado à limitação na mobilidade autorreferida. De acordo com os autores desse estudo, entre os indivíduos que relataram sentir dor há pelo menos 6 meses, 72,8% apresentavam limitação em algum das seguintes tarefas: caminhar uma rua (quadra); ficar sentado(a) durante duas horas, levantar-se de uma cadeira, curvar-se, ajoelhar-se ou agachar-se¹¹⁴.

Outro aspecto da mobilidade, normalmente avaliado pelo autorrelato, é a “mobilidade no espaço de vida”, na literatura conhecido como *life-space mobility*⁶³. Um instrumento de avaliação, contendo perguntas sobre a mobilidade no domicílio, na vizinhança, cidade e até fora dela, frequência e necessidade de equipamentos de suporte, vem sendo usado para mensurar o quanto um indivíduo explora os diferentes ambientes do seu entorno^{115,116}. Resultados de uma recente publicação mostrou o impacto das restrições sociais decorrentes da pandemia pela COVID-19 na *life-space mobility* de idosos brasileiros¹¹⁷. Como esperado, houve uma redução bastante drástica no deslocamento das pessoas idosas, e essa redução ocorreu de forma desigual entre diferentes grupos sociais. Embora o distanciamento social seja importante para redução da contaminação e transmissão do vírus, o estudo chama atenção para uma necessidade de ações que busquem superar a deterioração da mobilidade entre os idosos, sobretudo os grupos mais vulneráveis¹¹⁷.

1.5 MOBILIDADE E MORTALIDADE EM IDOSOS

Além do impacto direto no bem-estar e participação social dos indivíduos, o declínio da mobilidade tem sido considerado um forte preditor de mortalidade em pessoas idosas. Um estudo conduzido com dados de quase 500.000 indivíduos do Reino Unido mostrou que a velocidade da marcha habitual autorreferida foi um dos mais importantes preditores de mortalidade. Nesse estudo, homens que relataram ter uma velocidade reduzida apresentaram em média, 3,7 vezes a chance de óbito dos que disseram ter velocidade normal¹¹⁸. Outros estudos mostram, também, que além da associação com a mortalidade por todas as causas, essa variável estaria associada ao risco de morte por doenças cardiovasculares^{119,120}.

A velocidade da marcha, avaliada pelo tempo gasto para caminhar uma certa distância, também tem sido apresentada como um preditor de sobrevida na população idosa. Nofuji e colaboradores, em 2016, com uma amostra de 1.085 idosos japoneses mostraram que quanto maior a velocidade da caminhada, menor o risco de óbito por todas as causas e por doenças cardiovasculares. Para os óbitos por câncer, os autores não encontraram associações significativas¹²¹. White e colaboradores, 2013, mostraram, ainda, que a rapidez no declínio da velocidade da marcha também está associado a maior mortalidade, numa amostra de 2.364 indivíduos de 70 anos e mais⁸⁶.

Outros estudos também têm concluído que a velocidade da marcha é uma importante variável de predição para o óbito¹²²⁻¹²⁴, de forma que é recomendável que essa medida seja utilizada na prática clínica para rastreio de idosos com risco aumentado de morte^{123,124}. Num estudo recente, conduzido por Abe e colaboradores, 2019, a velocidade da caminhada esteve marginalmente associada à mortalidade, mas perdeu significância quando foi incluída a prática

de atividade física no modelo estatístico. Os autores sugerem, então, que a atividade física seria um fator de mediação na relação entre a velocidade da marcha e a mortalidade¹²⁵.

Outras medidas físicas de mobilidade, além da marcha, também são mencionadas na literatura como preditoras de óbito em idosos, como o TUG¹²⁶ e o SPPB^{100,127,128}, assim como a mobilidade autorreferida^{129,130}. No estudo de Olaya e colaboradores, 2018, aspectos como a dificuldade em ficar em pé por longos períodos e ajoelhar e agachar apresentaram associação mais forte com a mortalidade do que o autorrelato de dificuldade para caminhar uma distância de 100 metros, a despeito da maioria dos estudos da literatura, que geralmente focam na capacidade de caminhar como preditor de mortalidade^{129,131}.

São ainda escassos os estudos que tenham explorado a relação entre os diferentes aspectos da mobilidade funcional com a mortalidade em amostras representativas de idosos brasileiros, sobretudo considerando-se as causas específicas de óbito. Um seguimento de 15 anos com idosos residentes em Bambuí, Minas Gerais, mostrou que a dificuldade autorreferida em ao menos 1 tarefa de mobilidade, incluindo, caminhar, subir escadas, carregar objetos, e agachar ou ajoelhar, estava associado com maior risco de óbito¹³⁰. Em outro estudo, conduzido com idosos residentes na cidade de Pelotas, no Rio Grande do Sul, que teve o objetivo de analisar a sarcopenia como um preditor de mortalidade, os autores também observaram que a velocidade da marcha menor do que 0,8m/s estava associada ao aumento de 75% no risco de óbito, mesmo após ajuste pelas demais características demográficas e de saúde¹³². Em ambos estudos não foram analisados os óbitos por causas específicas.

2 OBJETIVOS

2.1 OBJETIVO GERAL

Analisar a relação entre a mobilidade funcional e a mortalidade em idosos residentes no município de São Paulo.

2.2 OBJETIVOS ESPECÍFICOS

1. Descrever a prevalência e os fatores associados ao comprometimento da mobilidade funcional na população idosa do município de São Paulo.
2. Avaliar a sobrevida de pessoas idosas de acordo com a mobilidade funcional, para todas as causas e para causas específicas de óbito.
3. Testar a performance de modelos preditivos de inteligência artificial (machine learning) para identificar de forma precoce os indivíduos idosos com maior risco de apresentar declínio da mobilidade funcional e óbito.

3 MÉTODOS

Para responder aos objetivos desta tese, foram desenvolvidos quatro artigos científicos, nos quais os dados utilizados foram provenientes do Estudo Saúde, Bem-Estar e Envelhecimento (SABE), um estudo longitudinal de múltiplas coortes, cuja amostra é representativa para a população de pessoas com 60 anos e mais, residentes no município de São Paulo.

A seguir, serão apresentados os métodos de planejamento, seleção da amostra e coleta de dados gerais do Estudo SABE, e, em seguida, os métodos específicos utilizados em cada um dos artigos desenvolvidos por esta tese.

3.1 ESTUDO SABE (SAÚDE, BEM-ESTAR E ENVELHECIMENTO)

O Estudo SABE tem como objetivo avaliar as condições de vida e saúde das pessoas idosas residentes no município de São Paulo. O estudo teve o seu primeiro inquérito conduzido no ano de 2000, quando foi coordenado pela Organização Pan-Americana de Saúde (OPAS/OMS). Naquele momento, era caracterizado por ser multicêntrico, conduzido no Município de São Paulo e em outros 6 centros urbanos da América Latina e Caribe: Buenos Aires (Argentina), Bridgetown (Barbados), Santiago (Chile), Havana (Cuba), Cidade do México (México) e Montevideu (Uruguai). Desde então, em São Paulo o estudo tem sido coordenado pela Faculdade de Saúde Pública da Universidade de São Paulo (FSP/USP) e financiado pela Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP).

A amostra do município de São Paulo, composta por dois seguimentos, foi formada por indivíduos com idade igual ou superior a 60 anos residentes em zona urbana. O primeiro segmento correspondeu à amostra probabilística e totalizou 1.568 entrevistas. A amostra de domicílios foi alcançada através de sorteio, para o qual foi utilizado o método de amostragem por conglomerados. Foi utilizado o cadastro permanente de 72 setores censitários, disponíveis no Departamento de Epidemiologia da FSP/USP.

O segundo segmento correspondeu ao acréscimo realizado para compensar a mortalidade dos idosos com idade acima de 75 anos, totalizando 575 indivíduos. O total de endereços de cada setor censitário foi dividido em grupos de 10 domicílios. Em cada setor foram sorteados nove grupos, de forma que 90 domicílios foram visitados. Todos os idosos elegíveis, de acordo com os objetivos do estudo, foram identificados e convidados a participar da entrevista. A amostra do ano de 2000 teve um total de 2.143 indivíduos idosos (Coorte A00).

A partir do ano de 2006 a versão brasileira do Estudo SABE passou a ter um caráter longitudinal, de forma que os idosos entrevistados no ano 2000 foram localizados e revisitados. Os óbitos foram identificados nas bases de dados municipais e estaduais e confirmados por informação de familiares e vizinhos durante as visitas. Dos 2.143 indivíduos participantes da primeira coorte, em 2000, 1.115 foram entrevistados novamente em 2006 (Coorte A06). Essa diferença ocorreu em decorrência dos óbitos, mudança de município, institucionalização, recusa e os não localizados. Além da amostra citada anteriormente foi introduzida uma nova coorte probabilística de 298 idosos com idade entre 60 e 64 anos (Coorte B06).

No ano de 2010 a terceira onda do Estudo SABE foi conduzida. Os indivíduos participantes das coortes de 2000 e 2006 foram localizados e visitados novamente. Da Coorte A foram entrevistados 748 indivíduos (Coorte A10) e da Coorte B, 230 indivíduos (Coorte B10). Além disso, uma nova coorte probabilística de 356 idosos com idade entre 60 e 64 anos foi incluída (Coorte C10), totalizando 1.334 indivíduos.

No ano de 2015 a última onda do SABE foi conduzida e, nesse momento, 382 indivíduos da Coorte A foram visitados (Coorte A15), 186 da Coorte B (Coorte B15), e 270 da Coorte C (Coorte C15). A nova coorte probabilista de indivíduos com 60 a 64 anos de idade foi composta por 386 pessoas (Coorte D15). O esquema do desenho amostral do SABE pode ser visto na Figura 2.

Figura 2: Desenho amostral do Estudo SABE

A coleta de dados do SABE foi realizada nos domicílios dos idosos, por uma equipe de entrevistadoras previamente treinada. A depender das condições cognitivas e físicas do indivíduo, um informante (cuidador ou familiar) poderia ser requisitado para aplicação do questionário padrão, que continha as seguintes sessões:

- A. Informações pessoais;
- B. Avaliação cognitiva;
- C. Estado de saúde;
- D. Estado funcional;
- E. Medicamentos;
- F. Uso e acesso a serviços;
- G. Rede de apoio familiar e social;
- H. História de trabalho e fonte de receita;
- J. Características da moradia;
- K. Antropometria;
- L. Testes de equilíbrio, mobilidade e flexibilidade.

O Estudo SABE foi aprovado pelo Comitê de Ética de Pesquisa em Seres Humanos da Faculdade de Saúde Pública da Universidade de São Paulo, sob pareceres de número 315/99, 1345, 2044, e 3.600.782. Todos os participantes assinaram o Termo de Consentimento Livre e Esclarecido, e a pesquisa respeitou os procedimentos éticos da Resolução nº 466 de 2012 (ANEXO I). Informações mais detalhadas sobre o Estudo SABE foram publicadas previamente por Lebrão e Duarte, 2003¹³³, e Lebrão et al, 2018⁴³.

3.2 MÉTODO DO ARTIGO 1

Para responder ao primeiro objetivo específico foi desenvolvido um estudo longitudinal seriado, que buscou descrever frequência de comprometimento da mobilidade funcional autorreferida e os fatores associados nas quatro ondas do estudo SABE. Além disso, buscou-se verificar a existência de diferença nessas frequências ao longo do período estudado.

Para isso, utilizou-se como desfecho de interesse a resposta “sim” ou “não pode” a qualquer uma das perguntas: “Tem alguma dificuldade em caminhar uma rua (quadra)?”, “Tem alguma dificuldade em subir um andar pelas escadas sem descansar?”, “Tem alguma dificuldade em se curvar, ajoelhar ou agachar?”, e “Encontra alguma dificuldade em levantar ou carregar pesos maiores que 5kg, como uma sacola de compras pesada?”. Para a análise de fatores associados foram incluídas características demográficas, socioeconômicas e relativas à saúde dos indivíduos, previamente relatados como fatores associados à condição de mobilidade em adultos idosos.

Foram incluídos 2.143 participantes da onda coletada no ano 2000, 1.413 de 2006, 1.344 de 2010 e 1.224 de 2015, sendo ajustados modelos de regressão logística bivariados e múltiplos, com resultados em termos de odds ratios (OR) e intervalos de confiança de 95% (IC95%), separadamente para cada onda do Estudo SABE.

Para verificar as diferenças entre as 4 ondas estudadas, foram ajustados modelos logísticos multinível. Nesses modelos, a dependência das observações decorrente do desenho longitudinal do estudo, em que um indivíduo pode ser revisitado nas ondas seguintes, foi considerada. Assim, foi adicionado um intercepto randômico aos modelos de regressão logística, considerando os indivíduos como o segundo nível de análise. Desse modo foram considerados os 6.114 registros referentes ao número total de entrevistas do estudo SABE como o primeiro nível de análise, e 3.183 indivíduos como o segundo nível das análises.

Seguindo as regras de defesa do Programa de Pós-Graduação em Saúde Pública da Faculdade de Saúde Pública da USP, esse manuscrito não foi submetido para publicação.

3.3 MÉTODO DO ARTIGO 2

Este artigo buscou responder o segundo objetivo específico da tese. Nele investigou-se a associação entre a mobilidade com a mortalidade por todas as causas e pelas principais causas específicas em pessoas idosas. Além disso, foi analisado se a condição de mobilidade dos indivíduos interferiria nos efeitos dos demais fatores de risco para o óbito.

Para essas análises foram utilizados os dados referentes à onda de 2006 do estudo SABE, composta por 1.413 indivíduos, além da data e causa básica do óbito, num seguimento de aproximadamente 10 anos. As informações referentes ao óbito foram obtidas por *linkage* entre os dados do Estudo SABE com os do Programa de Aprimoramento das Informações de Mortalidade no Município de São Paulo (PRO-AIM).

O desfecho deste estudo foi o tempo desde a entrevista, em 2006, até a data de óbito, com censura em setembro de 2016. As variáveis de interesse foram: velocidade da marcha, em metros/segundos, obtida pelo teste de caminhada de 3 metros; e o tempo necessário para levantar e sentar de uma cadeira 5 vezes, com tempos mais longos indicando pior estado de mobilidade.

Modelos de Cox ajustados por variáveis relacionadas à saúde, demográficas e socioeconômicas foram executados para analisar a associação entre ambas as medidas de mobilidade e a sobrevida por todas as causas e pelas 3 principais causas de óbito da amostra, de acordo com os seguintes capítulos da 10ª edição da Classificação Internacional de Doenças

(CID-10): Doenças do Aparelho Circulatório (I00-I99), Doenças do Aparelho Respiratório (J00-J99), e Neoplasias (C00-D48). Para verificar a existência de mudanças nos efeitos dos fatores de risco para mortalidade em grupos de diferentes condições de mobilidade, foram realizados modelos estratificados para o desempenho no teste de levantar e sentar, além de um modelo para o grupo de indivíduos incapazes de realizar o teste. Para as análises foi utilizado o pacote “survey” do R.

Esse manuscrito foi enviado para publicação para uma revista internacional e encontra-se em processo de avaliação pelos pareceristas. (ANEXO II)

3.4 MÉTODO DO ARTIGO 3

Este artigo, em conjunto com o artigo 4, buscou responder ao último objetivo específico do estudo: testar o uso de modelos para predições em idosos. Mais especificamente, este estudo comparou o desempenho de algoritmos de *machine learning* na predição de óbito por causas específicas, de acordo com os capítulos da CID-10, em pessoas idosas do município de São Paulo.

Para essas análises foram utilizados os dados da onda de 2006 e a coorte adicionada em 2010 (C10) do Estudo SABE, totalizando 1.767 indivíduos. Em 2006, o questionário do SABE apresentou acréscimos em relação à onda anterior, como a introdução dos itens da *Short Physical Performance Battery* (SPPB), na seção L (Mobilidade e Flexibilidade), que foram utilizados como variáveis preditoras neste estudo.

O desfecho de interesse foi a ocorrência ou não de óbito 5 anos após a entrevista de base. A variável resposta apresentou 5 categorias: ‘óbito por doenças do aparelho circulatório’/

‘óbito por doenças do aparelho respiratório’/ ‘óbito por neoplasias’/ ‘óbito por outras causas específicas’/ ou ‘não óbito’. Como preditores, foram incluídos dados sociodemográficos, relacionados à saúde, mobilidade funcional, doenças não transmissíveis, estado cognitivo e testes de performance física.

Foram treinados 14 algoritmos de ML em uma subamostra de treino, que correspondeu a 70% dos dados selecionados de forma aleatória. Foi empregada a validação cruzada 10-fold, utilizando o método de classificação “*one-versus-all*”. Nesse método, modelos de classificação binária são gerados para cada categoria. No caso desse artigo foram gerados cinco modelos em que cada categoria era considerada o desfecho, contra todo o restante da amostra¹³⁴.

A validação cruzada 10-fold pode ser utilizada quando não se dispõe de um grande banco de dados, não sendo possível reservar uma amostra de validação. Com este método, evita-se estimativas superestimadas dos modelos. Trata-se de dividir a amostra de treino em 10 partes iguais, sendo que 9 delas são usadas para treinar os modelos e a remanescente, para validar e gerar as estimativas dos algoritmos^{134,135}

Como os dados disponíveis eram desbalanceados, foram utilizados dois métodos de reamostragem na amostra de treino: a sobreamostragem aleatória (“*random over*”), que duplica aleatoriamente as observações das classes minoritárias, e a SMOTE (sobreamostragem minoritária sintética). Neste método são criadas novas observações sintéticas através de linhas traçadas entre um ponto e seus vizinhos mais próximos¹³⁶.

Os cinco algoritmos com melhores desempenhos foram aplicados nos 30% da amostra que haviam ficado de fora, sendo então calculadas as métricas de desempenho final: área abaixo da curva ROC (a relação entre a taxa de verdadeiros positivos e a taxa de falsos positivos), sensibilidade (a proporção de observações preditas corretamente como positivas para todos os realmente positivos), especificidade (a proporção de observações preditas corretamente como

negativas para todas as realmente negativas), *threshold* otimizado (o ponto de corte da probabilidade predita que maximiza a sensibilidade e especificidade) e a acurácia (percentual de acertos) entre os 25% dos indivíduos com maior probabilidade predita^{134,135,137}.

As variáveis que mais contribuíram para as predições finais foram ranqueadas de acordo com os valores de Shapley. Esse método é baseado na teoria dos jogos de coalizão, podendo ser interpretado como a contribuição média de uma variável para uma predição específica em comparação com a previsão média do conjunto de dados. A partir desses valores é possível observar a importância do preditor e seus efeitos¹³⁸.

As análises foram realizadas em Python. Para o treinamento dos algoritmos de aprendizado de máquina foi utilizada uma versão do PyCaret¹³⁹ customizada pelo Laboratório de Big Data e Análise Preditiva em Saúde (LABDAPS), o MLFlow.

O artigo resultante foi publicado na revista *Age and Ageing* (Qualis A1). (ANEXO III)

3.5 MÉTODO DO ARTIGO 4

Este artigo complementa o estudo anterior, buscando testar algoritmos preditivos que identifiquem de forma precoce idosos em risco de apresentar declínio funcional. Para isso, testamos o desempenho de algoritmos de *machine learning* em identificar indivíduos que apresentaram dificuldade em quatro tarefas relacionadas à mobilidade: caminhar uma quadra, subir um lance de escadas, agachar e ajoelhar, e carregar objetos com mais de 5 quilos.

Foram incluídos nas análises os indivíduos que entraram no Estudo SABE nos anos de 2000, 2006 e 2010 (Coortes A00, B06 e C10), e que foram localizados e revisitados na onda seguinte, totalizando 1.615 participantes. Assim, as variáveis preditoras foram obtidas na

entrevista de admissão no estudo, e os desfechos no seguimento, aproximadamente 5 anos depois. As predições foram realizadas para cada tarefa separadamente, e também para um desfecho único de declínio de mobilidade, ou seja, se o indivíduo relatou dificuldade em qualquer uma das quatro tarefas no seguimento. Para cada predição, os indivíduos com a presença da limitação correspondente na linha de base foram excluídos da análise. Por exemplo, indivíduos com limitação em subir degraus na admissão foram excluídos da análise de predição de limitação para subir degraus em cinco anos. Este procedimento gerou amostras diferentes para cada resultado analisado.

A maioria das variáveis preditoras incluídas nos modelos (características sociodemográficas e relacionadas à saúde) foi autorrelatada, com exceção do índice de massa corpórea (IMC) e do comprometimento cognitivo, que foi avaliado pela aplicação do Mini Exame do Estado Mental modificado, o que facilita a aplicação dos modelos em regiões remotas.

Os algoritmos de *machine learning* foram treinados em 70% dos dados, selecionados de forma aleatória. A escolha dos hiperparâmetros e o desempenho dos modelos foram analisados com base no valor da área abaixo da curva ROC. Os modelos foram aplicados em seguida nos 30% da amostra que ficaram de fora, para obtenção das métricas de desempenho nos dados de teste, conforme descrito na seção anterior. Nesse artigo também foi utilizado o MLFlow, a versão customizada do PyCaret¹³⁹ customizada pelo LABDAPS.

Uma tabela com resultados adicionais a este artigo foi adicionada no APÊNDICE I.

O manuscrito resultante dessa análise foi submetido para publicação em uma revista internacional e está em processo de avaliação pelos pareceristas. (ANEXO IV)

4 RESULTADOS E DISCUSSÃO

Os resultados e discussão estão apresentados na forma de coletânea de quatro artigos:

Artigo 1: *Mobilidade funcional autorreferida em idosos residentes no município de São Paulo, 2000-2015*

Artigo 2: *Functional Mobility and 10-year All-Cause and Cause-Specific Mortality in Older People from São Paulo, Brazil*

Artigo 3: *Cause-specific mortality prediction in older residents of São Paulo, Brazil: A machine learning approach*

Artigo 4: *Early identification of older individuals at risk of mobility decline with machine learning*

4.1 ARTIGO 1

Mobilidade funcional autorreferida em idosos residentes no município de São Paulo, 2000-2015

Autores:

Carla Ferreira do Nascimento¹,

Yeda Aparecida Oliveira Duarte²,

Alexandre Dias Porto Chiavegatto Filho¹

¹ Faculdade de Saúde Pública, Universidade de São Paulo, Av. Dr. Arnaldo, 715, CEP: 01246-904, São Paulo-, Brasil

² Escola de Enfermagem, Universidade de São Paulo, Av. Dr. Enéas Carvalho de Aguiar, 419, CEP: 05403-000, São Paulo-SP, Brasil

Mobilidade funcional autorreferida em idosos residentes no município de São Paulo, 2000-2015

Resumo

Este estudo tem como objetivo analisar a frequência de comprometimento da mobilidade funcional autorreferida e os fatores associados no período entre os anos 2000 e 2015, em idosos residentes no município de São Paulo. Para as presentes análises foram utilizados os dados das quatro ondas (2000, 2006, 2010 e 2015) do Estudo Saúde, Bem Estar e Envelhecimento (SABE), um estudo longitudinal, de múltiplas coortes, com amostra representativa para a população de pessoas com idade igual ou superior a 60 anos, residentes no município de São Paulo. Foram conduzidos modelos de regressão logística para analisar os fatores associados ao comprometimento da mobilidade em cada onda do estudo e modelos logísticos multinível para analisar a presença de diferenças entre as 4 ondas do estudo. O presente estudo indica um aumento nas prevalências de limitações na mobilidade autorreferida de idosos residentes no município de São Paulo entre 2000 e 2015. Observa-se, também associação com condições crônicas de saúde e aspectos socioeconômicos. Em um contexto de envelhecimento populacional acelerado, esses resultados trazem informações relevantes para a promoção de políticas públicas voltadas à prevenção de declínio da mobilidade em pessoas idosas.

Palavras chaves: Limitação da Mobilidade, Envelhecimento Populacional, Doenças Crônicas não Transmissíveis

Introdução

Nos últimos anos, a expectativa de vida da população mundial tem aumentado de forma significativa¹. Nesse cenário, a população com mais de 60 anos é a que tem apresentado maior velocidade no crescimento em relação às faixas etárias mais jovens, e esse fenômeno tem ocorrido de forma especialmente acelerada em regiões como a América Latina e Caribe². No Brasil, houve um crescimento de 92% na população idosa em um período de 20 anos de acordo com o último censo em 2010³, e projeções apontam que, em 2030, esta faixa etária corresponderá a quase 20% de toda a população¹. Apesar do aumento do tempo médio de vida na população, algumas evidências atuais têm mostrado que esse acréscimo muitas vezes vem acompanhado por incapacidades e comorbidades⁴.

A mobilidade funcional compreende diversas funções fundamentais para a participação social dos indivíduos, que incluem a mudança de posição do corpo, carregar, mover ou manipular objetos, caminhar, correr, e usar meios de transporte⁵. Com o avançar da idade, o risco de desenvolver declínio na mobilidade funcional tende a aumentar. Esse processo pode ocorrer como consequência do envelhecimento fisiológico dos sistemas corporais, da presença de doenças crônicas e de características ambientais⁶. Estima-se que 14% dos adultos do mundo apresentem alguma deficiência, incluindo dificuldades para se mover e para realizar o autocuidado⁷. No Brasil, entre adultos a partir de 60 anos, esse percentual foi de cerca de 15% no ano de 2015, e considerando apenas os idosos de 70 anos ou mais, de 24%⁸.

Além de causas biológicas, as limitações na mobilidade estão muito associadas aos aspectos socioeconômicos e demográficos, sendo um importante desafio, sobretudo em países com maiores taxas de desigualdades sociais⁸⁻¹⁰. Dessa forma, é importante conhecer a condição de mobilidade da população, identificando grupos mais vulneráveis ou com demandas específicas, para organização de políticas públicas de saúde e melhor alocação de recursos¹¹. Assim, este estudo tem como objetivo analisar a frequência de comprometimento da mobilidade

funcional autorreferida e os fatores associados no período entre os anos 2000 e 2015, em idosos residentes no município de São Paulo.

Métodos

Para as presentes análises foram utilizados os dados do Estudo Saúde, Bem Estar e Envelhecimento (SABE), um estudo longitudinal, de múltiplas coortes, com amostra representativa para a população de pessoas com idade igual ou superior a 60 anos, residentes no município de São Paulo. O Estudo SABE tem o objetivo primário de avaliar as condições de vida e saúde das pessoas idosas e é coordenado pelo departamento de Epidemiologia da Faculdade de Saúde Pública da Universidade de São Paulo. A coleta de dados do estudo foi realizada por entrevistas domiciliares realizada por profissionais treinadas, que aplicaram o questionário padronizado, contendo questões relacionadas às condições de saúde, dados pessoais e antropométricos, estado funcional, uso de medicamentos, história laboral, uso e acesso a serviços e características da morada.

Até o momento, o Estudo SABE possui quatro ondas, coletadas nos anos 2000, 2006, 2010 e 2015. A seleção dos indivíduos foi realizada através de amostragem probabilística por conglomerados, estratificada por sexo e faixa etária, realizada a partir de sorteio de domicílios com base no cadastro permanente de setores censitários da Pesquisa Nacional por Amostra de Domicílios (PNAD). A primeira onda do Estudo SABE, em 2000, teve 2.143 participantes e a cada nova onda os indivíduos eram localizados e revisitados. Além disso, novas coortes probabilísticas formadas por pessoas com 60 a 64 anos de idade eram adicionadas ao estudo a cada nova onda. Informações mais detalhadas sobre os métodos do Estudo SABE foram publicadas previamente^{12,13}.

O desfecho de interesse do presente estudo foi a presença de resposta “sim” ou “não pode” a qualquer uma das perguntas: “Tem alguma dificuldade em caminhar uma rua (quadra)?”, “Tem alguma dificuldade em subir um andar pelas escadas sem descansar?”, “Tem alguma dificuldade em se curvar, ajoelhar ou agachar?”, e “Encontra alguma dificuldade em levantar ou carregar pesos maiores que 5kg, como uma sacola de compras pesada?”. Para a análise de fatores associados foram incluídas características demográficas (faixa etária, sexo e raça/cor da pele), socioeconômicas (anos de escolaridade e percepção de suficiência de renda) e relativas à saúde dos indivíduos (consumo semanal de álcool, tabagismo, presença de doenças crônicas não transmissíveis (DCNT) - diabetes mellitus, doença pulmonar, doença cardíaca, acidente vascular cerebral (AVC) e doenças osteoarticulares, queixa de “dor nas costas”, declínio cognitivo avaliado pelo Mini Exame do Estado Mental modificado¹⁴, e história de queda nos últimos doze meses), previamente relatados como fatores associados à condição de mobilidade em adultos idosos.

Cada onda do estudo foi caracterizada de acordo com as variáveis socioeconômicas, demográficas e relacionadas à saúde, sendo também obtidas as frequências relativas segundo o desfecho e as variáveis explicativas. Em seguida, foram ajustados modelos de regressão logística bivariados e múltiplos, com resultados em termos de odds ratios (OR) e intervalos de confiança de 95% (IC95%), separadamente para cada onda do Estudo SABE. Todas essas análises consideraram a complexidade da amostra, sendo utilizado o pacote “Survey” do R. Por fim, foram ajustados modelos logísticos multinível para analisar a presença de diferenças entre as 4 ondas do estudo, relativas ao desfecho analisado. Nesses modelos, a dependência das observações decorrente do desenho longitudinal do Estudo, em que um indivíduo pode ser revisitado nas ondas seguintes, foi considerada. Assim, foi adicionado um intercepto randômico ao modelo de regressão logística, considerando os indivíduos como segundo nível de análise. Para o ajuste dos modelos multinível foi utilizado o pacote “lme4” do R.

Resultados

As amostras foram formadas por 2.143 indivíduos no ano de 2000, 1.413 em 2006, 1.344 em 2010 e 1.224 em 2015. Nas 4 ondas do Estudo SABE a faixa etária mais prevalente foi a de 60 a 69 anos, com proporção variando entre 54,2 a 59,1%. Observa-se, no entanto, um aumento ao longo dos 15 anos na proporção de indivíduos com 80 anos e mais, que em 2000 correspondia a 10,9% e passou a representar 15,2% da amostra na última onda do estudo. No que diz respeito ao sexo, o feminino foi o mais prevalente nas quatro ondas, com 58,8% da amostra em 2000, e 56,2% em 2015 (Tabela 1).

Outras características sociodemográficas que apresentaram mudanças ao longo dos 15 anos do estudo foi a escolaridade e a suficiência de renda. Observa-se que houve um aumento da proporção de indivíduos com maior escolaridade, sendo que em 2000, 17,6% dos idosos havia estudado por 8 anos ou mais, e essa proporção passou a ser de 31,4% na última onda analisada. Houve também um aumento na proporção de idosos que considerava a sua renda suficiente para cobrir as despesas, que era de 31,4%, em 2000, e na última onda passou a representar 52,1% dessa população, bem como na prevalência de algumas DCNT, como a hipertensão arterial, que de 52,8% subiu para 66,2%, e as doenças osteoarticulares, com aumento de 26,2% para 33,9% na última onda. A caracterização da amostra de acordo com as demais variáveis socioeconômicas, demográficas e de saúde nas quatro ondas do estudo pode ser vista na Tabela 1.

Tabela 1: Caracterização das ondas do Estudo SABE (%), São Paulo, 2000, 2006, 2010 e 2015.

Variável		Ondas			
		2000	2006	2010	2015
Mobilidade comprometida	Não	44,1	37,7	40,1	39,6
	Sim	55,9	62,3	59,9	60,4
Faixa etária	60 a 69	59,1	58,7	54,2	54,3
	70-79 anos	30,0	30,1	30,5	30,4
	80 e mais	10,9	11,2	15,3	15,2
Sexo	Masculino	41,2	40,6	40,1	43,8
	Feminino	58,8	59,4	59,9	56,2
Anos de estudo	até 3	47,2	42,2	34,5	24,7
	4 a 7 anos	35,2	38,6	37,5	43,8
	8 ou mais	17,6	19,2	28,0	31,4
Reside	Sozinho	13,2	13,2	15,3	16,0
	Acompanhado	86,8	86,8	84,7	84,0
Hipertensão arterial	Sim	52,8	62,6	66,7	66,2
	Não	47,2	37,4	33,3	33,8
Diabetes mellitus	Sim	16,6	21,0	25,0	28,2
	Não	83,4	79,0	75,0	71,8
Doença pulmonar	Sim	9,6	12,0	9,2	8,2
	Não	90,4	88,0	90,8	91,8
Doença cardíaca	Sim	17,8	22,0	22,9	23,8
	Não	82,2	78,0	77,1	76,2
Acidente vascular cerebral	Sim	7,3	8,3	7,0	7,0
	Não	92,7	91,7	93,0	93,0
Doenças osteoarticulares	Sim	26,8	32,4	31,8	33,9
	Não	73,2	67,6	68,2	66,1
Queixa de “dor nas costas”	Sim	39,7	20,6	16,7	16,3
	Não	60,3	79,4	83,3	83,7
Estado cognitivo	Comprometido	0,13	0,12	0,10	0,14
	Preservado	0,87	0,88	0,90	0,86
Alguma queda nos últimos 12 meses	Sim	28,6	28,5	29,6	28,8
	Não	71,4	71,5	70,4	71,2
Número de quedas nos últimos 12 meses	Nenhuma	72,2	71,6	70,4	71,4
	Uma	16,5	17,2	17,5	18,7
	2 ou mais	11,3	11,2	12,1	9,9
Raça/cor da pele	Branca	70,2	63,4	58,3	52,2
	Parda	21,1	20,2	29,1	37,1
	Preta	3,9	7,3	6,6	6,8
	Outras	4,9	9,1	6,0	3,9
Consumo semanal de bebidas alcoólicas	Menos de 1 dia	79,7	79,3	79,8	81,1
	1 a 3 dias	13,0	14,1	12,3	11,7
	4 ou mais dias	7,3	6,7	7,9	7,2
Tabagismo	Fuma atualmente	15,8	14,0	11,9	13,3
	Deixou de fumar	32,0	34,0	37,1	38,4
	Nunca fumou	52,1	52,0	51,0	48,3
Considera a renda suficiente para cobrir as despesas	Sim	31,4	44,9	57,0	52,1
	Não	68,6	55,1	43,0	47,9

A Figura 1 apresenta a frequência relativa de limitação em cada uma das quatro tarefas de mobilidade, para as quatro ondas do Estudo SABE. Observa-se que a capacidade de agachar é o item com maior número de queixa de limitação, seguido de carregar objetos, subir escadas e caminhar. Essa ordenação é observada nas 4 ondas analisadas. A Tabela Suplementar 1 apresenta as frequências absolutas e relativas de dificuldade em cada um dos 4 itens de mobilidade avaliados nas 3 primeiras ondas do Estudo SABE (2000, 2006 e 2010) de acordo com as ondas subsequentes (2006, 2010 e 2015).

Figura 1: Proporção de indivíduos com comprometimento em cada item autorreferido segundo onda do Estudo SABE.

Em relação à variável de interesse do estudo, ou seja, a dificuldade autorreferida em alguma das quatro tarefas relacionadas à mobilidade, verifica-se uma menor proporção no ano 2000 do que nos outros anos (Tabela 1). Essa diferença foi significativa, como pode ser observado pelas razões de chance apresentadas na Tabela 2, que mostra OR [IC95%] de 1,59 [1,31-1,93] para a onda 2006, de 1,40 [1,41-1,71] para 2010, e 1,29 [1,04-1,60] para 2015, quando a onda 2000 era referência, mesmo após ajuste pelas demais variáveis. Esses resultados indicam que as chances de limitação na mobilidade foram significativamente maiores nos anos de 2006 a 2015, se comparados com o ano de 2000.

Tabela 2: Modelos de regressão logística multinível para prevalência de mobilidade comprometida em cada onda do Estudo SABE (São Paulo, 2000, 2006, 2010, 2015).

Ondas	Modelos não ajustados			Modelos ajustados ^a		
	OR	IC(95%)		OR	IC(95%)	
(Ref.: 2000)						
2006	1,84	(1,60;2,06)	***	1,59	(1,31;1,93)	***
2010	1,55	(1,52;2,21)	***	1,40	(1,41;1,71)	**
2015	1,45	(1,18;1,79)	***	1,29	(1,04;1,60)	*
AIC		7596,0			6389,8	
n (2º nível)		3183			3141	
n (1º nível)		6114			5931	

Ondas	Modelos não ajustados			Modelos ajustados ^a		
	OR	IC(95%)		OR	IC(95%)	
(Ref.: 2006)						
2010	0,82	(0,66;1,00)		0,83	(0,67;1,03)	
2015	0,79	(0,64;0,99)	*	0,81	(0,65;1,02)	
AIC		4890,2			4117,2	
n (2º nível)		2155			2184	
n (1º nível)		3971			3844	

Ondas	Modelos não ajustados			Modelos ajustados ^a		
	OR	IC(95%)		OR	IC(95%)	
(Ref.: 2010)						
2015	0,96	(0,78;1,17)		0,92	(0,75;1,14)	

AIC	3295,4	2756,2
n (2º nível)	1720	1694
n (1º nível)	2558	2475

*p<0,05; **p<0,01; ***p<0,001. ^aModelos ajustado pelas variáveis de saúde, socioeconômicas e demográficas listadas na Tabela 1.

Quanto aos fatores de risco, analisados pelos modelos de regressão não ajustados, na Tabela 3, e ajustados, na Tabela 4, observa-se que as idades mais avançadas estavam associadas positivamente com a queixa de limitação na mobilidade nos 4 modelos, com OR [IC95%] de 3,25 [2,30-4,60], 4,36 [2,81-6,75], 2,08 [1,37-3,16] e 2,17 [1,33-3,55], respectivamente (Tabela 4). Outras variáveis que também apresentaram associação significativa nas 4 ondas do SABE foram o sexo feminino, com OR [IC95%] variando de 1,86 [1,29-2,69] a 2,11 [1,58-2,83], a história de AVC, com OR [IC95%] de 2,97 [1,30-6,75] a 7,98 [3,88-16,42], a presença de doenças osteoarticulares, com OR [IC95%] de 2,33 [1,73-3,16] a 3,07 [2,18-4,34], e a queixa de “dor nas costas”, que apresentou OR [IC95%] variando de 2,61 [1,63-4,16] a 4,15 [2,52-6,83] (Tabela 4).

Tabela 3: Odds Ratios (OR) não ajustadas e seus respectivos intervalos de confiança à 95% (IC) para mobilidade comprometida (São Paulo, 2000, 2006, 2010, 2015).

Variáveis	2000			2006			2010			2015		
	OR	IC(95%)		OR	IC(95%)		OR	IC(95%)		OR	IC(95%)	
Faixa etária (ref.: 60 a 69)												
70 a 79	1,78	(1,43;2,20)	***	1,77	(1,34;2,34)	***	1,85	(1,4;2,44)	***	1,46	(1,10;1,93)	**
80 e mais	3,61	(2,77;4,72)	***	5,41	(3,79;7,71)	***	3,22	(2,36;4,40)	***	2,73	(1,89;3,95)	***
Sexo (ref.: masculino)												
Feminino	2,38	(1,93;2,93)	***	2,61	(2,00;3,40)	***	3,03	(2,35;3,91)	***	2,90	(2,26;3,71)	***
Anos de estudo (ref.: 8 ou mais)												
4 a 7 anos	1,37	(1,02;1,83)	*	1,24	(0,88;1,76)		2,26	(1,64;3,11)	***	1,43	(1,07;1,91)	*
até 3 anos	2,08	(1,57;2,75)	***	2,12	(1,48;3,01)	***	3,40	(2,45;4,71)	***	2,21	(1,56;3,13)	***
Com quem reside (ref.: acompanhado)												
Sozinho	1,29	(0,98;1,71)		0,99	(0,71;1,43)		1,34	(0,95;1,89)		1,05	(0,76;1,46)	
Hipertensão arterial	2,17	(1,77;2,66)	***	2,33	(1,79;3,02)	***	2,35	(1,80;3,05)	***	2,01	(1,55;2,60)	***
Diabetes mellitus	1,39	(1,06;1,03)	*	1,62	(1,16;2,26)	**	1,61	(1,19;2,17)	**	1,63	(1,23;2,16)	***
Doença pulmonar	1,56	(1,10;2,22)	*	1,93	(1,24;3,02)	**	3,25	(1,94;5,43)	***	2,93	(1,70;5,05)	***
Doença cardíaca	1,95	(1,48;2,56)	***	2,31	(1,64;3,25)	***	2,01	(1,46;2,75)	***	2,63	(1,89;3,65)	***
Acidente vascular cerebral	7,07	(3,85;12,98)	***	5,18	(2,31;11,60)	***	5,47	(2,92;10,27)	***	4,18	(2,07;8,45)	***
Doenças osteoarticulares	3,38	(2,62;4,35)	***	4,20	(3,05;5,78)	***	3,72	(2,78;4,99)	***	4,39	(3,25;5,92)	***
Queixa de “dor nas costas”	3,62	(2,90;4,52)	***	4,54	(2,97;6,93)	***	4,16	(2,66;6,52)	***	3,03	(2,04;4,50)	***
Comprometimento cognitivo	2,92	(2,09;4,07)	***	3,00	(1,84;4,90)	***	3,47	(2,26;5,34)	***	2,10	(1,44;3,07)	***
Número de quedas nos últimos 12 meses (ref.: nenhuma)												
Uma	1,29	(0,97;1,70)		1,78	(1,25;2,52)	**	1,36	(0,97;1,89)		1,17	(0,85;1,60)	
2 ou mais	3,48	(2,41;5,01)	***	4,12	(2,43;6,99)	***	3,99	(2,43;6,54)	***	2,90	(1,83;4,60)	***
Raça/cor da pele (ref.: branca)												
Parda	1,25	(0,97;1,62)		1,08	(0,78;1,50)		1,04	(0,79;1,37)		0,89	(0,68;1,16)	
Preta	1,19	(0,70;1,99)		1,21	(0,73;2,01)		1,37	(0,84;2,25)		0,91	(0,57;1,48)	
Outras	0,53	(0,33;0,84)	**	0,96	(0,67;1,63)		0,61	(0,36;1,03)		0,57	(0,57;1,48)	
Consumo de álcool (ref.: Até 1 dia/semana)												
1 a 3 dias/semana	0,45	(0,33;0,62)	*	0,35	(0,24;0,51)	***	0,27	(0,18;0,40)	***	0,35	(0,23;0,52)	***
4 ou mais dias/semana	0,51	(0,34;0,76)	*	0,31	(0,18;0,53)	***	0,36	(0,22;0,58)	***	0,33	(0,20;0,55)	***
Tabagismo (ref.: nunca fumou)												
Fuma atualmente	0,81	(0,60;1,09)		0,70	(0,47;1,03)		0,88	(0,58;1,34)		0,52	(0,36;0,76)	***
Deixou de fumar	0,87	(0,70;1,09)		0,74	(0,56;0,98)	*	0,81	(0,62;1,05)		0,82	(0,62;1,06)	

Considera a renda suficiente para cobrir as despesas (ref.: sim)

Não	1,90	(1,54;2,36)	***	1,40	(1,08;1,80)	*	1,96	(1,53;2,51)	***	1,79	(1,38;2,31)	***
-----	------	-------------	-----	------	-------------	---	------	-------------	-----	------	--------------	-----

*p<0,05; **p<0,01; ***p<0,001

Outros aspectos da saúde que, embora não tenham apresentado associação significativa em todas as ondas, mostraram correlações importantes em alguns modelos foram a hipertensão arterial (OR [IC95%] em 2000 de 1,69 [1,32-2,17] e em 2006 de 1,74 [1,25-2,41]), as doenças pulmonares (OR [IC95%] em 2006 de 2,11 [1,30-3,42] e em 2015 de 3,00 [1,57-5,74]), e as cardiopatias (OR [IC95%] em 2006 de 2,09 [1,39-3,15] e em 2015 de 1,91 [1,27-2,87]). Além disso, o declínio cognitivo (OR [IC95%] em 2000 de 2,29 [1,56-3,36] e em 2015 de 1,83 [1,14-2,95]) e a história de duas quedas ou mais nos últimos 12 meses (OR [IC95%] em 2000 de 2,02 [1,31-3,13] e em 2010 de 3,06 [1,72-5,46]) também se mostraram associados ao desfecho, em alguns dos modelos ajustados (Tabela 4).

A escolaridade baixa se associou ao desfecho no ano 2010, com OR [IC95%] de 1,86 [1,26-2,74] e 2,02 [1,34-3,04], para 4 a 7 anos de escolaridade, e até 3 anos, respectivamente. A ausência de renda suficiente teve associação significativa em 2000 (OR [IC95%] = 1,82 [1,40-2,36]), em 2010 (OR [IC95%] = 1,53 [1,13-2,07]) e em 2015 (OR [IC95%] = 1,51 [1,12-2,04]) (Tabela 4).

No que diz respeito às associações negativas com a presença de limitação em alguma das 4 tarefas, o consumo de álcool teve associações significativas a partir de 2006, com OR [95%] variando entre 0,40 [0,25-0,62] a 0,63 [0,40-0,99], para um consumo de 1-3 dias por semana. É importante ressaltar que as variáveis que apresentaram associações estatisticamente significativas em alguns modelos apresentaram a mesma direção dos efeitos nas demais ondas, indicando consistência nas associações. As ORs das demais variáveis e seus respectivos ICs estão apresentados na Tabela 4.

Tabela 4: Resultados das regressões logísticas múltiplas apresentados em termos de Odds Ratios (OR) e seus respectivos intervalos de confiança à 95% (IC), para mobilidade comprometida (São Paulo, 2000, 2006, 2010, 2015).

Variáveis	2000			2006			2010			2015		
	OR	IC(95%)		OR	IC(95%)		OR	IC(95%)		OR	IC(95%)	
Idade (Ref. 60 a 69)												
70 a 79	1,74	(1,34;2,24)	***	1,50	(1,07;2,10)	*	1,41	(1,00;1,98)		1,13	(0,79;1,59)	
80 e mais	3,25	(2,30;4,60)	***	4,36	(2,81;6,75)	***	2,08	(1,37;3,16)	***	2,17	(1,33;3,55)	**
Sexo feminino	2,11	(1,58;2,83)	***	1,86	(1,29;2,69)	***	2,07	(1,50;2,86)	***	2,08	(1,52;2,84)	***
Raça/cor da pele (Ref. Branca)												
Parda	0,98	(0,70;1,36)		0,97	(0,64;1,45)		0,88	(0,62;1,24)		0,90	(0,64;1,26)	
Preta	1,03	(0,57;1,86)		0,98	(0,51;1,90)		1,18	(0,61;2,27)		0,78	(0,46;1,31)	
Outras	0,50	(0,31;0,82)	**	0,95	(0,56;1,61)		0,59	(0,29;1,18)		0,52	(0,24;1,12)	
Anos de estudo (8 anos ou mais)												
4 a 7 anos	1,04	(0,73;1,47)		1,04	(0,67;1,61)		1,86	(1,26;2,74)	**	1,25	(0,87;1,80)	
Até 3 anos	1,04	(0,73;1,48)		1,46	(0,93;2,28)		2,02	(1,34;3,04)	***	1,19	(0,76;1,85)	
Mora sozinho	1,11	(0,78;1,57)		0,72	(0,47;1,09)		1,06	(0,68;1,65)		0,81	(0,54;1,23)	
Não recebe renda suficiente	1,82	(1,40;2,36)	***	1,30	(0,95;1,78)		1,53	(1,13;2,07)	**	1,51	(1,12;2,04)	**
Consumo de álcool (Ref.: menos de 1 dia/semana)												
1 a 3 dias/semana	0,70	(0,48;1,01)		0,63	(0,40;0,99)	*	0,40	(0,25;0,62)	**	0,60	(0,36;0,98)	*
4 dias ou mais/semana	0,84	(0,51;1,35)		0,52	(0,26;1,04)		0,85	(0,45;1,62)	***	0,59	(0,31;1,12)	
Tabagismo (ref.: Nunca fumou)												
Parou de fumar	1,40	(1,03;1,89)	*	0,86	(0,59;1,27)		1,08	(0,78;1,49)		0,90	(0,66;1,25)	
Fuma atualmente	1,46	(1,00;2,13)		1,09	(0,65;1,82)		1,42	(0,84;2,43)		0,87	(0,53;1,43)	
Hipertensão arterial	1,69	(1,32;2,17)	***	1,74	(1,25;2,41)	***	1,68	(1,22;2,31)	**	1,30	(0,96;1,76)	
Diabetes mellitus	1,22	(0,87;1,70)		1,33	(0,89;2,00)		1,31	(0,91;1,89)		1,50	(1,07;2,09)	*
Doença pulmonar	1,35	(0,87;2,10)		2,11	(1,30;3,42)	**	2,74	(1,57;4,78)	***	3,00	(1,57;5,74)	***
Doença cardíaca	1,54	(1,11;2,14)	*	2,09	(1,39;3,15)	***	1,40	(0,96;2,03)		1,91	(1,27;2,87)	**
Acidente vascular cerebral	7,98	(3,88;16,42)	***	5,87	(2,37;14,50)	***	4,40	(2,01;9,59)	***	2,97	(1,30;6,75)	**
Doenças osteoarticulares	2,33	(1,73;3,14)	***	2,93	(2,01;4,27)	***	2,62	(1,86;3,70)	***	3,07	(2,18;4,34)	***
Queixa de “dor nas costas”	3,12	(2,40;4,06)	***	4,15	(2,52;6,83)	***	3,43	(2,13;5,52)	***	2,61	(1,63;4,16)	***
Declínio cognitivo	2,29	(1,56;3,36)	***	1,61	(0,85;3,07)		1,99	(1,08;3,68)	*	1,83	(1,14;2,95)	*
Número de quedas no último ano (ref. Nenhuma)												
Uma	0,98	(0,70;1,37)		1,42	(0,93;2,17)		0,94	(0,65;1,37)		0,97	(0,66;1,43)	
2 ou mais	2,02	(1,31;3,13)	**	2,54	(1,32;4,88)	**	3,06	(1,72;5,46)	***	1,69	(0,99;2,86)	

*p<0,05; **p<0,01; ***p<0,001

Discussão

O presente estudo indica um aumento nas prevalências de limitações na mobilidade autorreferida de idosos residentes no município de São Paulo entre 2000 e 2015. Verificou-se também que outras características socioeconômicas e epidemiológicas se modificaram ao longo do tempo, como a presença de doenças crônicas, a escolaridade e a suficiência de renda, o que justifica parcialmente os resultados encontrados. É importante ressaltar que após ajuste pelos potenciais fatores de confusão, as diferenças na prevalência de limitações na mobilidade em 2006, 2010 e 2015 permaneceram significativamente diferentes da primeira onda do SABE, em 2000 (Tabela 2). Observa-se, por outro lado, que a última coorte, de 2015, apresentou uma prevalência significativamente menor do que a do ano 2006, após ajuste pelas variáveis individuais. Esse resultado pode significar uma tendência na redução da proporção de idosos com mobilidade comprometida, porém não é possível concluir essa hipótese a partir dos dados analisados.

Um estudo de base populacional, conduzido em 1998, encontrou que mais de 60% da população de idosos brasileiros apresentava alguma dificuldade autorreferida em tarefas de mobilidade, sendo que entre as mulheres essa prevalência ultrapassava os 80%¹⁵. Nesse estudo, além de tarefas como caminhar, ajoelhar, agachar, e subir escadas, outras também foram investigadas, como caminhar distâncias maiores do que 1 quilômetro, se alimentar, ir ao banheiro, e praticar esportes¹⁵. A inclusão de tarefas com maior grau de dificuldade, provavelmente aumentou o número de indivíduos com queixa na mobilidade. Ainda nesse estudo os autores encontraram que a proporção de idosos com dificuldade para ajoelhar e agachar foi em torno de 50%, sendo maior do que 50% para subir escadas¹⁵.

Um outro estudo, que comparou os resultados da Pesquisa Nacional por Amostra de Domicílios (PNAD) dos anos de 1998 e 2003, encontrou uma redução na proporção de idosos brasileiros com dificuldade para caminhar uma distância de 100 metros, mesmo quando

analisados os valores estratificados por região¹⁶. No Sudeste, por exemplo, a prevalência era de 24,4% em 1998, e reduziu para 22,1% em 2003¹⁶. Esse estudo teve um caráter descritivo, não se propondo a realizar análises ajustadas por outros fatores. Além disso, a questão referente ao desfecho analisado era diferente da pergunta sobre dificuldade para caminhar presente no questionário do Estudo SABE, o que pode justificar as diferenças encontradas.

Estudos conduzidos em outros países também mostram resultados variados acerca das limitações na mobilidade. Em um estudo de base populacional de Uganda, observou-se que 28,4% dos indivíduos apresentavam dificuldade para caminhar ou subir escadas¹⁷. Em outro estudo, com amostra representativa da população com 55 anos e mais de Singapura, verificou-se que mais de 90% dos indivíduos era independente na locomoção e não precisava de dispositivos de auxílio. Esse estudo, assim como a presente análise, buscou comparar a prevalência de limitação na mobilidade ao longo do tempo, e observou um aumento, principalmente nas faixas etárias mais avançadas, entre os anos 1995 e 2005¹⁸.

Nota-se, entre os estudos encontrados, importantes diferenças metodológicas¹⁵⁻¹⁸. Essas diferenças dizem respeito às questões ou perguntas utilizadas nos questionários e às análises empregadas, além dos perfis socioeconômicos, demográficos e culturais das populações estudadas. Esses aspectos dificultam a comparação dos resultados e talvez justifiquem diferenças tão expressivas nas estimativas quando comparadas com as do presente estudo.

Análises similares às deste estudo foram realizadas previamente, com o objetivo de comparar as mudanças na morbidade por doenças cardiovasculares em idosos moradores da cidade de São Paulo entre os anos 2000 e 2010¹⁹. Nesse estudo, os autores encontraram um aumento das chances de doenças cardiovasculares em 2006 e 2010, em relação ao ano 2000, mesmo nos modelos ajustados¹⁹. Isso corrobora com os presentes achados, indicando um padrão de piora das condições crônicas na década que sucedeu ao ano 2000, o que provavelmente refletiu na capacidade funcional e de mobilidade dos idosos. Esse padrão de

crescimento das condições crônicas se alinha com o processo de transição epidemiológica brasileiro observado por Marinho e colaboradores, num estudo publicado em 2018²⁰. De acordo com os resultados desses autores, houve uma melhora geral da condição de saúde da população entre os anos de 1990 a 2016, com redução das causas infecciosas e neonatais de morte, porém com o crescimento no peso das doenças crônicas, que passaram a ser as principais causas de incapacidade na população²⁰.

A análise dos fatores de risco mostrou que algumas características apresentaram associações consistentes nos quatro momentos analisados, como a faixa etária, o sexo, a presença de algumas DCNT, e a queixa de dor lombar. Embora não determine uma perda funcional, a idade é considerada um fator de risco bem estabelecido na literatura para declínio de mobilidade²¹. Sabe-se que o impacto de comorbidades, das características ambientais e socioeconômicas são mais evidentes com o avançar da idade, aumentando o risco de os indivíduos desenvolverem dificuldades na locomoção e na realização de outras atividades funcionais^{21,22}. As mulheres, embora tenham uma sobrevida média maior do que os homens, também apresentam maior risco de desenvolverem incapacidades^{23,24}, fato corroborado com os resultados deste estudo, que mostraram que elas apresentam de 2 a 3 vezes a chance dos homens, de apresentar limitação na mobilidade.

Outro aspecto que também é estabelecido como um importante fator de risco para o desenvolvimento de limitações funcionais é a presença de doenças crônicas²⁵. Algumas condições são conhecidas por causar impactos diretos na capacidade de locomoção e mobilidade, como as doenças cerebrovasculares,^{26,27} e as desordens musculoesqueléticas e articulares²⁸, o que também pode ser observado nos resultados deste estudo. Uma análise publicada recentemente mostrou que a dor lombar é a queixa que mais contribui para a necessidade de serviços de reabilitação e de saída prematura do trabalho, seguida por outras condições osteoarticulares, como a osteoartrite²⁹. O AVC, por sua vez, tem apresentado

incidência e prevalência crescentes em números absolutos, sendo uma das principais causas de incapacidade na população^{26,27}.

A presença acumulada de doenças crônicas contribui para uma cadeia de alterações que culminam em inatividade física, imobilidade e depressão, entre outras condições adversas na saúde^{20,25}. Uma das consequências dessa cadeia pode ser o aumento do risco de quedas, que, por sua vez, também gera consequências como o medo de cair, lesões físicas, e a própria imobilidade³⁰. Dessa forma, os resultados deste estudo corroboram com a literatura em mostrar a associação entre esses aspectos e mobilidade funcional autorreferida.

Alguns aspectos também se associaram com o desfecho analisado, mas não em todas as ondas do Estudo SABE. Em relação às características sociais, a menor escolaridade teve associação com a queixa de limitação na mobilidade no ano de 2010, e a percepção de suficiência de renda em 2000, 2010 e 2015. Ambas variáveis são consideradas proxy para a condição socioeconômica dos indivíduos, e apontadas em publicações prévias como fatores de risco para piores condições de saúde, inclusive a mobilidade^{31,32}. Essa relação pode ocorrer devido ao acesso mais difícil aos serviços de saúde, a comportamentos de risco mais frequentes, bem como pelo comprometimento do bem-estar psicológico causado pelo estresse^{31,33,34}.

Os comportamentos de risco, como o consumo de álcool e de tabaco, também tiveram associações significativas em parte das ondas. Vale ressaltar, porém, que a natureza transversal das análises, bem como o tipo de pergunta que não considera as intensidades e as doses consumidas, tornam o resultado sujeito a vieses. Estudos têm apontado que as associações positivas encontradas entre o consumo moderado de álcool e melhores condições de saúde podem ocorrer pelo fato de que o grupo de comparação dos abstêmios, muitas vezes apresentam algum problema de saúde³⁵. Estudos com delineamento longitudinal e com diferentes métodos de mensuração do consumo de álcool suportam essa hipótese, mostrando os efeitos deletérios dose-dependentes do alcoolismo na saúde geral dos indivíduos^{35,36}. Quanto ao tabaco, o

consenso é que não existem doses seguras para o seu uso³⁷. Os resultados da coorte de 2000 mostraram que indivíduos que já haviam fumado apresentaram, em média, maiores chances de ter a mobilidade comprometida, quando comparados com aqueles que nunca fumaram. A mesma direção de associação foi observada para os que se declararam fumantes, porém sem significância estatística.

É importante levantar algumas limitações do presente estudo. Primeiro, os dados foram obtidos a partir de entrevista, estando sujeitos a vieses de memória. Deve-se ressaltar que nos casos de idosos do estudo com déficit cognitivo, uma pessoa próxima era requisitada a responder ao questionário como proxy. Segundo, as informações sobre o consumo de álcool foram referentes aos 3 meses anteriores à entrevista, não sendo possível analisar de forma mais específica a quantidade ingerida. Além disso, a ocorrência de quedas também foi referente apenas aos 12 meses anteriores. Para ambas as variáveis, embora a pergunta referente ao período mais próximo à entrevista reduza o risco de viés de memória, é possível que informações anteriores importantes tenham sido perdidas. Por fim, a característica seriada das análises não permite inferir causalidade, de forma que os efeitos observados devem ser interpretados com cautela.

Os resultados do presente estudo apontam para um aumento das limitações da mobilidade funcional entre pessoas idosas residentes no município de São Paulo num período de 15 anos e a sua relação com condições crônicas de saúde e aspectos socioeconômicos. Em um contexto de envelhecimento populacional acelerado, esses resultados trazem informações relevantes para a promoção de políticas públicas voltadas à prevenção de declínio da mobilidade, com ampliação do acesso a grupos mais vulneráveis.

Referências

1. United Nations Department of Economic and Social Affairs/Population Division. World Population Prospects 2019. Published 2019. Accessed March 6, 2021.
<https://population.un.org/wpp/Graphs/Probabilistic/PopPerc/60plus/76>
2. United Nations. *World Population Ageing*; 2015. Doi:ST/ESA/SER.A/390
3. Ministério da Saúde. Departamento de Informática do Sistema Único de Saúde (DATASUS). Published 2020. Accessed July 28, 2020.
<http://www2.datasus.gov.br/DATASUS/index.php?area=0206&id=6942&Vobj=http://tabnet.datasus.gov.br/cgi/defctohtm.exe?ibge/cnv/pop>
4. Lee J, Lau S, Meijer E, Hu P. Living Longer, With or Without Disability? A Global and Longitudinal Perspective. Newman A, ed. *Journals Gerontol Ser A*. 2020;75(1):162-167. Doi:10.1093/gerona/glz007
5. World Health Organization. *International Classification of Functioning, Disability and Health*. WHO; 2001.
6. Rantakokko M, Mäntä M, Rantanen T. Mobility Decline in Old Age. *Exerc Sport Sci Rev*. 2013;41(1):19-25. Doi:10.1097/JES.0b013e3182556f1e
7. Mitra S, Sambamoorthi U. Disability prevalence among adults: estimates for 54 countries and progress toward a global estimate. *Disabil Rehabil*. 2014;36(11):940-947. Doi:10.3109/09638288.2013.825333
8. Andrade FB de, Duarte YA de O, Souza Junior PRB de, Torres JL, Lima-Costa MF, Andrade FCD. Inequalities in basic activities of daily living among older adults. *ver Saude Publica*. 2019;52(Suppl 2):14s. doi:10.11606/s1518-8787.2018052000617
9. Alves LC, Leite I da C, Machado CJ. Fatores associados à incapacidade funcional dos

idosos no Brasil: análise multinível. *Rev Saude Publica*. 2010;44(3):468-478.

doi:10.1590/S0034-89102010005000009

10. Biritwum RB, Minicuci N, Yawson AE, et al. Prevalence of and factors associated with frailty and disability in older adults from China, Ghana, India, Mexico, Russia and South Africa. *Maturitas*. 2016;91:8-18. doi:10.1016/j.maturitas.2016.05.012
11. Watfe GMP, Fajersztajn L, Ribeiro E, Menezes PR, Scazufca M. Prevalence of Older Adult Disability and Primary Health Care Responsiveness in Low-Income Communities. *Life*. 2020;10(133):1-14. doi:10.3390/life10080133
12. Lebrão ML, Duarte YA de O, Santos JLF, Silva NN da. 10 Years of SABE Study: background, methodology and organization of the survey. *Rev Bras Epidemiol*. 2018;21(suppl 2). doi:10.1590/1980-549720180002.supl.2
13. Lebrão ML, Duarte YA de O. *O Projeto SABE No Município de São Paulo: Uma Abordagem Inicial*. 1st ed. Organização Pan-Americana de Saúde; 2003.
14. Icaza MG, Albala C. Minimental State Examination (MMSE) del estudio de vejez en Chile: análisis estadístico. Published online 1999:1-18.
15. Melzer D, Parahyba MI. Socio-demographic correlates of mobility disability in older Brazilians: results of the first national survey. *Age Ageing*. 2004;33(3):253-259. doi:10.1093/ageing/afh075
16. Parahyba MI, Simões CC da S. A prevalência de incapacidade funcional em idosos no Brasil. *Cien Saude Colet*. 2006;11(4):967-974. doi:10.1590/S1413-81232006000400018
17. Wandera SO, Ntozi J, Kwagala B. Prevalence and correlates of disability among older Ugandans: evidence from the Uganda National Household Survey. *Glob Health Action*. 2014;7(1):25686. doi:10.3402/gha.v7.25686

18. Yong V, Saito Y, Chan A. Changes in the Prevalence of Mobility Limitations and Mobile Life Expectancy of Older Adults in Singapore, 1995-2005. *J Aging Health*. 2010;22(1):120-140. doi:10.1177/0898264309351932
19. Massa KHC, Duarte YAO, Chiavegatto Filho ADP. Análise da prevalência de doenças cardiovasculares e fatores associados em idosos, 2000-2010. *Cien Saude Colet*. 2019;24(1):105-114. doi:10.1590/1413-81232018241.02072017
20. Marinho F, de Azeredo Passos VM, Carvalho Malta D, et al. Burden of disease in Brazil, 1990–2016: a systematic subnational analysis for the Global Burden of Disease Study 2016. *Lancet*. 2018;392(10149):760-775. doi:10.1016/S0140-6736(18)31221-2
21. Ferrucci L, Cooper R, Shardell M, Simonsick EM, Schrack JA, Kuh D. Age-Related Change in Mobility: Perspectives From Life Course Epidemiology and Geroscience. *Journals Gerontol Ser A Biol Sci Med Sci*. 2016;71(9):1184-1194. doi:10.1093/gerona/glw043
22. Duim E, Lima Passos V. Highways–to Ageing - Linking life course SEP to multivariate trajectories of health outcomes in older adults. *Arch Gerontol Geriatr*. 2020;91(July):104193. doi:10.1016/j.archger.2020.104193
23. Ahmed T, Vafaei A, Auais M, Guralnik J, Zunzunegui MV. Gender Roles and Physical Function in Older Adults: Cross-Sectional Analysis of the International Mobility in Aging Study (IMIAS). Ginsberg SD, ed. *PLoS One*. 2016;11(6):e0156828. doi:10.1371/journal.pone.0156828
24. Roman Lay AA, Ferreira do Nascimento C, Caba Burgos F, et al. Gender Differences between Multimorbidity and All-Cause Mortality among Older Adults. *Curr Gerontol Geriatr Res*. 2020;2020:1-7. doi:10.1155/2020/7816785
25. Costa Filho AM, Mambrini JV de M, Malta DC, Lima-Costa MF, Peixoto SV.

- Contribution of chronic diseases to the prevalence of disability in basic and instrumental activities of daily living in elderly Brazilians: the National Health Survey (2013). *Cad Saude Publica*. 2018;34(1):1-12. doi:10.1590/0102-311x00204016
26. Lotufo PA, Goulart AC, Passos VM de A, et al. Doença cerebrovascular no Brasil de 1990 a 2015: Global Burden of Disease 2015. *Rev Bras Epidemiol*. 2017;20(suppl 1):129-141. doi:10.1590/1980-5497201700050011
 27. Ouriques Martins SC, Sacks C, Hacke W, et al. Priorities to reduce the burden of stroke in Latin American countries. *Lancet Neurol*. 2019;18(7):674-683. doi:10.1016/S1474-4422(19)30068-7
 28. Vos T, Abajobir AA, Abate KH, et al. Global, regional, and national incidence, prevalence, and years lived with disability for 328 diseases and injuries for 195 countries, 1990–2016: a systematic analysis for the Global Burden of Disease Study 2016. *Lancet*. 2017;390(10100):1211-1259. doi:10.1016/S0140-6736(17)32154-2
 29. Cieza A, Causey K, Kamenov K, Hanson SW, Chatterji S, Vos T. Global estimates of the need for rehabilitation based on the Global Burden of Disease study 2019: a systematic analysis for the Global Burden of Disease Study 2019. *Lancet*. 2020;396(10267):2006-2017. doi:10.1016/S0140-6736(20)32340-0
 30. Hartholt KA, van Beeck EF, Polinder S, et al. Societal Consequences of Falls in the Older Population: Injuries, Healthcare Costs, and Long-Term Reduced Quality of Life. *J Trauma Inj Infect Crit Care*. 2011;71(3):748-753. doi:10.1097/TA.0b013e3181f6f5e5
 31. Foster HME, Celis-Morales CA, Nicholl BI, et al. The effect of socioeconomic deprivation on the association between an extended measurement of unhealthy lifestyle factors and health outcomes: a prospective analysis of the UK Biobank cohort. *Lancet Public Heal*. 2018;3(12):E576-e585. doi:10.1016/S2468-2667(18)30200-7

32. Stringhini S, Carmeli C, Jokela M, et al. Socioeconomic status, non-communicable disease risk factors, and walking speed in older adults: multi-cohort population based study. *BMJ*. 2018;360:k1046. doi:10.1136/bmj.k1046
33. Chen E, Miller GE. Socioeconomic Status and Health: Mediating and Moderating Factors. *Annu Rev Clin Psychol*. 2013;9(1):723-749. doi:10.1146/annurev-clinpsy-050212-185634
34. Almeida APSC, Nunes BP, Duro SMS, Facchini LA. Socioeconomic determinants of access to health services among older adults: a systematic review. *Rev Saude Publica*. 2017;51:1-15. doi:10.1590/s1518-8787.2017051006661
35. Stockwell T, Zhao J, Panwar S, Roemer A, Naimi T, Chikritzhs T. Do “Moderate” Drinkers Have Reduced Mortality Risk? A Systematic Review and Meta-Analysis of Alcohol Consumption and All-Cause Mortality. *J Stud Alcohol Drugs*. 2016;77(2):185-198. doi:10.15288/jsad.2016.77.185
36. Ortolá R, García-Esquinas E, López-García E, León-Muñoz LM, Banegas JR, Rodríguez-Artalejo F. Alcohol consumption and all-cause mortality in older adults in Spain: an analysis accounting for the main methodological issues. *Addiction*. 2019;114(1):59-68. doi:10.1111/add.14402
37. Inoue-Choi M, Liao LM, Reyes-Guzman C, Hartge P, Caporaso N, Freedman ND. Association of Long-term, Low-Intensity Smoking With All-Cause and Cause-Specific Mortality in the National Institutes of Health–AARP Diet and Health Study. *JAMA Intern Med*. 2017;177(1):87-95. doi:10.1001/jamainternmed.20111

Material Suplementar

Tabela Suplementar 1: Frequência de dificuldade em 4 itens de mobilidade nas 3 primeiras ondas do Estudo SABE de acordo com as ondas subsequentes. Estudo SABE, 2000, 2006, 2010 e 2015.

Onda	Desfechos	2006																2010																2015																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																	
		n*	Dificuldade para caminhar				Dificuldade para subir escadas				Dificuldade para agachar				Dificuldade para carregar pesos				n*	Dificuldade para caminhar				Dificuldade para subir escadas				Dificuldade para agachar				Dificuldade para carregar pesos				n*	Dificuldade para caminhar				Dificuldade para subir escadas				Dificuldade para agachar				Dificuldade para carregar pesos																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																		
			Sim	%	Não	%	Sim	%	Não	%	Sim	%	Não	%	Sim	%	Não	%		Sim	%	Não	%	Sim	%	Não	%	Sim	%	Não	%	Sim	%	Não	%		Sim	%	Não	%	Sim	%	Não	%	Sim	%	Não	%																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																			
2000	Dificuldade para caminhar	Sim	119	89	74,8	30	25,2	104	87,4	15	12,6	104	87,4	15	12,6	98	82,4	21	17,6	50	37	74,0	13	26,0	45	90,0	4	8,0	40	80,0	9	18,0	43	86,0	7	14,0	18	16	88,9	2	11,1	17	94,4	1	5,6	18	100,0	0	0,0	16	88,9	2	11,1																																																																																																																																																																																																																																																																																																																																																																																																																																																																																														
	Não	995	225	22,6	770	77,4	413	41,5	577	58,0	572	57,5	421	42,3	478	48,0	515	51,8	698	188	26,9	501	71,8	303	43,4	381	54,6	382	54,7	304	43,6	333	47,7	352	50,4	364	114	31,3	243	66,8	147	40,4	210	57,7	214	58,8	142	39,0	189	51,9	166	45,6																																																																																																																																																																																																																																																																																																																																																																																																																																																																																															
	Dificuldade para subir escadas	Sim	296	160	54,1	136	45,9	221	74,7	73	24,7	244	82,4	51	17,2	231	78,0	64	21,6	160	87	54,4	71	44,4	122	76,3	35	21,9	121	75,6	35	21,9	121	75,6	36	22,5	73	45	61,6	26	35,6	55	75,3	16	21,9	63	86,3	8	11,0	61	83,6	9	12,3																																																																																																																																																																																																																																																																																																																																																																																																																																																																																														
	Não	817	153	18,7	664	81,3	296	36,2	518	63,4	431	52,8	385	47,1	344	42,1	472	57,8	587	138	23,5	442	75,3	226	38,5	349	59,5	301	51,3	277	47,2	255	43,4	322	54,9	309	85	27,5	219	70,9	109	35,3	195	63,1	169	54,7	134	43,4	144	46,6	159	51,5																																																																																																																																																																																																																																																																																																																																																																																																																																																																																															
	Dificuldade para agachar	Sim	526	224	42,6	302	57,4	328	62,4	196	37,3	417	79,3	107	20,3	350	66,5	174	33,1	324	133	41,0	186	57,4	202	62,3	115	35,5	244	75,3	73	22,5	204	63,0	113	34,9	162	77	47,5	82	50,6	97	59,9	62	38,3	126	77,8	32	19,8	108	66,7	49	30,2																																																																																																																																																																																																																																																																																																																																																																																																																																																																																														
	Não	588	90	15,3	498	84,7	189	32,1	396	67,3	259	44,0	329	56,0	226	38,4	362	61,6	424	92	21,7	328	77,4	146	34,4	270	63,7	178	42,0	240	56,6	172	40,6	246	58,0	220	53	24,1	163	74,1	67	30,5	149	67,7	106	48,2	110	50,0	97	44,1	119	54,1																																																																																																																																																																																																																																																																																																																																																																																																																																																																																															
2006	Dificuldade para carregar pesos	Sim	293	156	53,2	137	46,8	202	68,9	89	30,4	239	81,6	53	18,1	236	80,5	56	19,1	162	82	50,6	77	47,5	117	72,2	41	25,3	129	79,6	29	17,9	128	79,0	30	18,5	73	42	57,5	30	41,1	49	67,1	23	31,5	60	82,2	12	16,4	55	75,3	16	21,9																																																																																																																																																																																																																																																																																																																																																																																																																																																																																														
	Não	821	158	19,2	663	80,8	315	38,4	503	61,3	437	53,2	386	47,0	340	41,4	480	58,5	586	143	24,4	437	74,6	231	39,4	344	58,7	293	50,0	284	48,5	248	42,3	329	56,1	309	88	28,5	215	69,6	115	37,2	188	60,8	172	55,7	130	42,1	150	48,5	152	49,2																																																																																																																																																																																																																																																																																																																																																																																																																																																																																															
	Dificuldade para caminhar	Sim	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-

* Corresponde à frequência absoluta de indivíduos que participaram de ambas ondas, de acordo com a resposta aos itens de mobilidade.

4.2 ARTIGO 2

Functional Mobility and 10-year All-Cause and Cause-Specific Mortality in Older People from São Paulo, Brazil

Authors:

Carla Ferreira do Nascimento (<http://orcid.org/0000-0002-0054-277X>)^{1*};

Alejandra Andrea Roman Lay (<https://orcid.org/0000-0002-2530-0443>)²;

Yeda Aparecida Oliveira Duarte (<http://orcid.org/0000-0003-3933-2179>)³;

Alexandre Dias Porto Chiavegatto Filho (<http://orcid.org/0000-0003-3251-9600>)¹.

¹ School of Public Health, University of São Paulo, Av. Dr. Arnaldo, 715, CEP: 01246-904, São Paulo-SP, Brazil

² Faculty of Health Sciences, University of Tarapacá, 18 de Septiembre, 2222, Arica, 1000000, Chile

³ School of Nursing, University of São Paulo, Av. Dr. Enéas Carvalho de Aguiar, 419, CEP: 05403-000, São Paulo-SP, Brazil

* **Corresponding author:** Carla Ferreira do Nascimento, Department of Epidemiology, School of Public Health, University of São Paulo, Avenida Doutor Arnaldo, 715, 1º andar, CEP: 01246-904, Telephone number: 55 (11)3061-7737. E-mail: nascimento.cfd@gmail.com

Functional Mobility and 10-year All-Cause and Cause-Specific Mortality in Older People from São Paulo, Brazil

Abstract

Aims: To analyze all-cause and cause-specific mortality according to gait speed and chair stand test performance in a representative sample of adults aged 60 and over.

Methods: We analyzed the results of SABE (Health, Well-being and Aging Study), a multiple-cohort study conducted in São Paulo, Brazil. Cox regression models were used to analyze all-cause and cause-specific mortality according to gait speed and the chair stand test, and further adjusted by health, socioeconomic, and demographic risk factors.

Results: Of the 1,411 participants, 26% died during the 10-year follow-up. The performance in the chair stand test had a more consistent association with mortality (HR=1.03, IC95% 1.00-1.05) than gait speed. Individuals that were unable to perform the test also had an increased risk to die by all-cause (HR=1.71, IC95% 1.21-2.42) and by diseases of the circulatory system (HR=2.14, IC95% 1.25-3.65). The stratified analysis of mobility performance changed the effects of some of the mortality risk factors.

Conclusions: Our results bring new insights regarding functional mobility measures and mortality patterns in a socioeconomically diverse population from the largest city of the Americas, and support the development of preventive interventions and public policies targeted at specific mobility groups.

Keywords: gait speed, chair stand test, survival, cause-specific mortality

Introduction

Functional mobility can be defined as the ability to move independently from a place to another[1], and comprises several functions that involve changing body position, carrying, moving or manipulating objects, walking, running, climbing, and even using transportation[2].

There are many qualitative and quantitative options to evaluate functional mobility. Simple physical performance tests, such as gait speed and the chair stand test, have been used as predictors of adverse health outcomes in older populations[3–6]. Human gait results from the synchronous functioning of the motor, sensory, and cognitive systems, and the speed that an older person performs this task is sometimes considered the “sixth vital sign”, an important marker of individual overall health status[5,7]. The ability to rise from a sitting position is also essential to functional independence, and to maintain a physical active life[8]. The performance in this task is frequently used to assess lower limb function and to predict future health conditions such as falls and disabilities in older adults[4].

Slow gait speed and worst performance in other mobility measures has been associated to increased mortality risk[9,10]. A pooled analysis, including data from São Paulo, Brazil, proposed a model to predict mortality in older adults, and the self-reported difficulty in walking several blocks appeared as an important risk factor[11]. Other studies among Brazilian individuals aged 60 years and more have shown that the difficulty in walking across the bedroom and in going to the bathroom[12], the decline in muscle mass strength[13], and the number of self-reported mobility difficulties were associated with mortality[14].

The relationship of mobility disability with mortality is well established; however, a better understanding of the mortality patterns for the different causes of death, especially in terms of performance in functional mobility tasks, is still a challenge for the Brazilian older population. With this study, we aim to analyze if gait speed and chair stand test performance are associated

with all-cause and cause-specific mortality in older adults from São Paulo, Brazil, and if the overall mobility condition changes the effect of other mortality risk factors.

Methods

Sample and data collection

We analyzed data from SABE (Health, Well-being and Aging Study), a multiple cohort study that is representative of older community-dwelling individuals living in São Paulo, Brazil. The first wave of SABE was conducted in 2000 as a multicenter study from 7 urban areas of Latin-America and Caribe and was coordinated by the Pan-American Health Organization (PAHO) and the Department of Epidemiology of School of Public Health of the University of São Paulo. The SABE study of the municipality of São Paulo, Brazil, is composed of a representative sample of people aged 60 years and more. In brief, individuals were selected by clusters from an initial sample of 72 census tracts, selected by a probability proportional to size approach. More details about the sampling strategy have been previously described elsewhere[15]. In São Paulo, a total of three other waves were collected in 2006, 2010, and 2015. In 2006, physical assessments such as gait speed were first added to the questionnaire, so this cohort was used as the baseline data for our analysis (n=1,413). From this original sample, two individuals were excluded, one due to missing data related to the census tracts and the other due to incompatibility between the date of the interview and the date of death, resulting in 1,411 individuals. The SABE Study received approval from the Human Research Ethics Committee of the School of Public Health/University of São Paulo (protocol number 315/99, 83/06, and 2044) and all participants gave written informed consent.

Outcomes

The outcomes of interest were time from the baseline interview (2006) to death for all causes, and separately for the three most frequent causes of death, according to the chapters of the 10th revision of the International Classification of Diseases (ICD-10): diseases of the circulatory system (I00-I99), diseases of the respiratory system (J00-J99), and neoplasms (C00-D48). The distribution of the mortality sample according to codes of the three ICD-10 chapters is presented in Supplementary Table 1. Mortality data were obtained by a linkage between the SABE records and the death registry database from the Program for Improvement of Mortality Information in the Municipality of São Paulo (PRO-AIM), until September 13th, 2016, totaling 10 years, with a maximum time of follow-up of 10.4 years. Individuals without mortality information until this date were considered censored for the survival analysis. Figure 1 shows the flow diagram of the study.

Variables of interest

Gait speed was evaluated by the time needed to walk a distance of 3 meters, with longer times meaning worse condition. The 3-meter walk test is part of the Short Physical Performance Battery (SPPB)[16], that evaluates lower body function. Gait speed was measured twice, and the shortest time was considered. The following instruction was given to the participants: *“This is our walking course. I want you to walk to the other end of the course at your usual speed, just as if you were walking down the street to go to the store.”* The timer was started when the participant began to walk and stopped as soon as the participant completed the distance. For the analysis, we calculated the gait speed as the distance in meters divided by time in seconds. We also analyzed this variable according to three categories, considering the individuals with speed $\leq 0.8\text{m/s}$ as having reduced gait speed[13], and individuals who were not able to perform the test as another category (composed mostly of bedridden or wheelchair-bound individuals, those who were

physically unable to perform physical tests while standing or walking, and those who refused to perform the walk test because they felt unsafe).

The chair stand test is also part of the SPPB but widely used as a single test for measuring mobility disability and lower extremity function[3,16]. Participants were asked to stand up from a chair 5 times consecutively as quickly as possible without hand support, and the time to complete the task was recorded (in seconds). We also performed analysis with this variable according to three categories (not able/ time higher than 14 seconds/ time equal or less than 14s). The cut-off point was proposed by Santos et al, 2016, based on a sample composed of Brazilian older adults[17].

Covariates

Other independent variables included in models were age, gender, the block of socioeconomic features (years of education (none, 1–3, 4–7, 8 or more years), race/skin color (white, black or mixed, others) and living alone (yes/no)), and the block of health variables (cognitive impairment (measured by the modified version of Mini-Mental State Examination, validated in a study conducted by Icaza & Albala, 1999[18], to minimize possible effects of low education on the test result), multimorbidity (the self-reported presence of two or more of the following diseases: hypertension, diabetes mellitus, musculoskeletal disorders (osteoarthritis, rheumatoid arthritis), cerebrovascular, pulmonary or cardiovascular diseases), alcohol intake (never, up to 1 day/week, 2 days/week or more), smoking status (never, currently or have ever smoked), and body mass index (BMI) (underweight, normal weight, overweight or obesity) according to the PAHO[19]).

Statistical analysis

Baseline description of variables is presented in terms of percentage, for the whole sample and for the categories of the two mobility measures. We performed the log-rank test to equality of survival curves according to these factors. Continuous variables were described in terms of their mean and standard deviation.

Cox regression models were performed to analyze the association between the independent variables and all-cause and specific mortality. We tested models adjusted by the block of socioeconomic variables, by the health variables, and by both. All models were adjusted by age and sex. We also adjusted stratified models for the three different levels of functional mobility, as evaluated by the chair stand test. We chose this test for this analysis because it had a more consistent association with mortality, as observed in the results section. The proportional hazard assumption of the models was tested by the Schoenfeld test. All analyses were performed considering sample weights with the *survey* package of R software (available in [<https://cran.r-project.org/>]).

Results

From a total of 1,411 individuals, 26% died during the 10-year follow-up, 39.3% by diseases of the circulatory system, 20.9% by neoplasms, and 17.0% by diseases of the respiratory system. Supplementary Table 1 shows the distribution of the sample according to the 3 most frequent ICD-10's chapters. Mean age at baseline was 68 years, 59% were female, 58% had gait speed less than 0.8m/s, and 14% performed the chair stand test in more than 14 seconds. Table 1 shows the baseline characteristics of the sample according to socioeconomic, demographic and health variables, and the distribution of the sample according to gait speed and the chair stand test. From the total of individuals, 2.4% were excluded from the multiple analysis due to missing values (25 in BMI, 4 in education, 4 in alcohol intake, and 3 in 'living alone').

Table 2 presents the HR and 95%CI according to baseline gait speed and chair stand test for all-cause and cause-specific mortality. It shows that gait speed had a negative association with all-cause mortality (HR=0.52, CI95% 0.30-0.88) in the first model (adjusted by age and gender), but the association lost significance when adjusted by social and health variables. When analyzed as a categorical variable, slow gait speed was positively associated with all-cause mortality when adjusted by sex, age and socioeconomic variables (HR=1.47, CI95% 1.09-1.99 in Model 1, and HR=1.44, CI95% 1.06-1.94, in Model 2), but not when adjusted by health features (Table 2).

Regarding the time to perform the chair stand test, both the continuous and categorized variables maintained a significant association with all-cause mortality, even adjusted by all variables. In the first model, adjusted by age and gender, the HR was 1.03 (CI95% 1.01-1.05), and in the model adjusted by age, sex, socioeconomic and health features, the HR was 1.03 (CI95% 1.00-1.05). These associations were also observed with the chair stand test categorized by the cut-off point of 14s. The group that performed the test in >14 seconds had, on average, 39% higher risk to die than those who performed in a shorter time, with a CI95% of 1.05-1.85, independently from the demographic, socioeconomic and health features (Table 2).

Not having performed both tests presented a consistent risk effect on all-cause mortality, with HR=1.80 (CI95% 1.20-2.70) for inability to perform the walking test, and HR 1.71 (CI95% 1.21-2.42) for inability to perform the chair stand test, adjusted by all blocks of variables. Regarding the cause-specific mortality, these inability were also associated with the risk to die by diseases of the circulatory system, even when adjusted by the co-variables (HR=2.44, CI95% 1.30-4.56, for inability to carry out the walking test, and HR=2.14, CI95% 1.25-3.65, for inability to perform the chair stand test) (Table 2). Regarding the other specific-causes of death, the results were less consistent across the models. These results are presented in Table 2.

Table 3 shows the HR of demographic, health and socioeconomic models, stratified by mobility performance according to the chair stand test. The first model, that included those who performed the test in 14 seconds or less, found a negative association of alcohol consumption up to 1 day a week with all-cause mortality (HR=0.35, CI95% 0.16-0.77). Still in the first model, smoking was an important mortality risk factor (HR=2.29, IC95% 1.24-4.22), as well as in the second model that include individuals who performed the test in more than 14 seconds. In this second model, we found a positive association of being black or mixed-race (HR=1.73, IC95% 1.20-2.49), and of cognitive impairment (HR=1.89, IC95% 1.26-2.83), with mortality. In the last model, which included individuals who were not able to perform the test, the positive association with cognitive impairment maintained, and an association with the presence of 2 or more non-communicable diseases was also significant (HR=1.75, IC95% 1.15-2.67). Interestingly, in the last model we observed an inversion of the effect of being black or mixed-race, i.e. there was a negative association with mortality (HR=0.62, CI95% 0.41-0.95).

Discussion

Our study aimed to analyze the mortality of older individuals according to mobility conditions, assessed by gait speed and by the chair stand test. Despite the fact that the association between gait speed and mortality was not significant for most statistical models, the time necessary to complete the chair stand test was a consistent mortality risk factor. Moreover, our results highlight that individual mobility condition could modify the effects of other mortality risk factors.

Previous studies have shown that usual walking speed is a predictor of all-cause mortality, and some authors have suggested the routine use of this measure in clinical practice[9]. White et al., 2013, analyzed trajectories of gait speed in older adults and found that the group with the fastest

decline had a higher overall risk of death[6]. However, the authors did not analyze interactions with other risk factors. Differently from most studies in this field, the walking time of our sample was taken in a 3-meters distance, while other authors have used larger distances[5,9,20].

Considering that shorter walks are more influenced by the acceleration phase, previous studies have recommended performing the gait speed test over distances longer than 4 meters[7]. It may be the case that measures with longer distances are more associated with mortality, which could explain the non-significant association between all-cause mortality and reduced gait speed in our adjusted models. Similar results were found by Yu et al., 2019, that measured gait speed at a distance of 2.4 meters, in older community-dwelling individuals without cognitive impairment[21]. Nevertheless, previous studies suggest that 3 or 4-meter tests could be used in limited spaces[7,22].

Although gait speed is more studied as a predictor of mortality in older adults, in our results, the time to perform the chair stand test had a more consistent association with all-cause mortality risk. A study conducted on 622 Italian older individuals has shown that the time to perform the chair stand test was a better predictor of mobility disability than gait speed, even when measured in a distance of 7-meters[4]. Other studies have also shown the ability of the chair stand test to predict a decline in activities of daily living[3]. Differently from the present study, Rolland et al., 2006, have found that the time to complete the chair stand test was not associated with mortality after adjustment by confounders[23]. The authors included as covariates the ability to walk outdoors and instrumental activities of daily living, which could dilute the effect of mobility in the risk of death. Similar results were observed in a more recent study, in which the time to perform the chair stand test was also not associated with mortality after adjustment by covariates[24]. In both studies, the follow-up period was shorter than our study.

Regarding cause-specific mortality, in our study gait speed presented bordering associations with death by diseases of the circulatory system. Nofuji et al., 2016, when analyzing a sample composed of Japanese older adults, found an association of walking speed with mortality by cardiovascular diseases, but not by cancer[20]. In our results, there was an association of slow gait speed and mortality by neoplasm in the fully-adjusted model.

It is interesting to note that the groups unable to perform both tests had an increased risk to die by all-causes and by diseases of the circulatory system, supporting the idea that people in the worst mobility condition are more vulnerable to adverse outcomes[25]. On the one hand, the mobility limitation increases the risk of sedentary behavior[26], which is associated with higher mortality. On the other hand, cardiovascular risk can predict frailty and mobility limitation[27]. This two-way relation could partially help to explain the causal mechanism of the increased mortality risk in the more disabled groups.

Our stratified analysis revealed that the functional mobility performance can modify the effects of mortality risk factors. Individuals with cognitive impairment and poor mobility condition, i.e., worst performance or inability to perform the chair stand test, appear to be more vulnerable to the adverse outcome, according to our results. Studies support that age-related mobility decline and cognitive function are strongly correlated, and that mobility decline could predict impairment in cognition[28]. Evidences also confirm that cognitive impairment increases the risk of death in older adults, and this association could be stronger when cognition and mobility interact with each other[21,29].

In the group with the worst mobility condition, the presence of two or more NCD was more important as a mortality risk than in the other groups. The literature highlights the role of chronic diseases in triggering disabilities[30]. However, there are complex mechanisms involving physical frailty and chronic diseases, such as cardiovascular events and diabetes, that help to explain our

findings[31,32]. Previous analyses have shown that multimorbidity is a risk factor for higher mortality, but it is subject to the number and combination of present chronic diseases[33]. According to our results, the combination of multimorbidity and mobility limitation also increases mortality risk.

Health behaviors, such as smoking and alcohol consumption, were associated with mortality risk in the best mobility groups. More specifically, alcohol consumption up to 1 day per week, had a protective effect in the group with faster performance in the chair stand test. There is a lot of evidence that heavy drinkers have a higher risk of death, however, some studies have shown that moderate alcohol use is associated with overall better health[34], and therefore with a lower risk of death[35]. Measuring unit/day consumption, as performed by Ortolá et al., 2019, was not possible in our study; however, our findings are consistent with this literature since individuals in best mobility level and that drink up to 1 drink/week had, on average, lower mortality risk compared to those who never drink alcohol[36].

Having a current smoking habit presented a risk effect on all-cause mortality in the groups that performed the chair stand test. Smoking is an important and consistent mortality risk for the overall population and also for older adults[37]. Both alcohol consumption and smoking were measured only in baseline, so we were not able to assess changes over time until the end of follow-up, which could influence the results. Considering the time-dependent characteristic of these variables, especially in individuals with disabilities, this could help to explain our results, especially given the fact that there is no risk-free level of exposure to tobacco smoke[37].

In the stratified analysis, some social aspects did not present significant associations; however, being black or mixed was positively associated with mortality in the slowest group, but negatively in the unable group. Historically, black and mixed individuals have been at social disadvantage worldwide, and according to the literature, they have a higher risk of death and many

other adverse health outcomes[38,39]. However, opposite to what was expected, being black and mixed had a protective effect against mortality among the group unable to perform the chair stand test. Latham et al, 2015, also observed that the black individuals were more likely to recover their mobility than Whites[40]. Nevertheless, some aspects should be considered before interpreting our result. First, a selection bias could have influenced the baseline characteristics of the sample, since the study was not designed to be representative of race/skin color[39]. Second, we cannot exclude the possibility of bias due to the presence of mortality before the baseline interview, as life trajectories of disabled people according to race could explain this result. However, we highlight the importance of giving special attention to the health of black and mixed individuals, especially if they are in the worst mobility condition.

This study has some limitations. First, mortality data was obtained by linkage, so the existence of a few missing individuals cannot be ruled out. To avoid this, we manually checked all detected pairs, and also performed a one-by-one search of all unpaired individuals. Second, some variables such as the presence of NCD, were self-reported. To avoid memory bias, we questioned everyone from the sample if a health professional ever told them they had each specific disease (e.g. *“Did a doctor or nurse ever tell you that you have Diabetes Mellitus?”*). However, there is the issue of the presence of non-diagnosed diseases, so these results could be underestimated. Third, for some of the categorical variables, we did not find a dose-response relationship with mortality, and we cannot exclude the possibility of unmeasured potential confounders. Fourth, the distance measure for gait speed was shorter than for some published papers, being likely less sensitive to small changes in mobility status. On the other hand, it allowed the assessment of walking time in a community-dwelling sample of a large and socially unequal city, where individuals do not always have enough space in their homes.

Our results bring new insights concerning mortality patterns from an ethnic and socioeconomic diverse population by all-cause and cause-specific mortality. To the best of our knowledge, there are no studies that analyzed mortality risk factors stratified by mobility performance levels in a representative sample of Brazil. Our findings support the development of preventive interventions and public policies targeted at specific mobility groups of older adults from large urban centers. We highlight the need of special attention to those with worse mobility since their difficulty in locomotion puts them at a disadvantage in accessing public health services.

References

- [1] A. Patla, A. Shumway-cook, Dimensions of mobility: Defining the complexity and difficulty associated with community mobility, *J. Aging Phys. Act.* 7 (1999) 7–19. <https://doi.org/10.1177/053901847201100504>.
- [2] Centro Colaborador da Organização Mundial da Saúde para a Família da Classificações Internacionais em Português, *Classificação Internacional de Funcionalidade, Incapacidade e Saúde*, 1st ed., Editora da Universidade de São Paulo, São Paulo, 2015.
- [3] F. Zhang, L. Ferrucci, E. Culham, E.J. Metter, J. Guralnik, N. Deshpande, Performance on Five Times Sit-to-Stand Task as a Predictor of Subsequent Falls and Disability in Older Persons, *J. Aging Health.* 25 (2013) 478–492. <https://doi.org/10.1177/0898264313475813>.
- [4] N. Deshpande, E.J. Metter, J. Guralnik, S. Bandinelli, L. Ferrucci, Predicting 3-Year Incident Mobility Disability in Middle-Aged and Older Adults Using Physical Performance Tests, *Arch. Phys. Med. Rehabil.* 94 (2013) 994–997. <https://doi.org/10.1016/j.apmr.2012.10.032>.
- [5] S. Studenski, S. Perera, K. Patel, C. Rosano, K. Faulkner, M. Inzitari, J. Brach, J.

- Chandler, P. Cawthon, E.B. Connor, M. Nevitt, M. Visser, S. Kritchevsky, S. Badinelli, T. Harris, A.B. Newman, J. Cauley, L. Ferrucci, J. Guralnik, Gait Speed and Survival in Older Adults, *JAMA*. 305 (2011) 50. <https://doi.org/10.1001/jama.2010.1923>.
- [6] D.K. White, T. Neogi, M.C. Nevitt, C.E. Petoquin, Y. Zhu, R.M. Boudreau, J.A. Cauley, L. Ferrucci, T.B. Harris, S.M. Satterfield, E.M. Simonsick, E.S. Strotmeyer, Y. Zhang, Trajectories of Gait Speed Predict Mortality in Well-Functioning Older Adults: The Health, Aging and Body Composition Study, *Journals Gerontol. Ser. A Biol. Sci. Med. Sci.* 68 (2013) 456–464. <https://doi.org/10.1093/gerona/gls197>.
- [7] A. Middleton, S.L. Fritz, M. Lusardi, Walking Speed: The Functional Vital Sign, *J. Aging Phys. Act.* 23 (2015) 314–322. <https://doi.org/10.1123/japa.2013-0236>.
- [8] R.C. van Lummel, S. Walgaard, M. Pijnappels, P.J.M. Elders, J. Garcia-Aymerich, J.H. van Dieën, P.J. Beek, Physical Performance and Physical Activity in Older Adults: Associated but Separate Domains of Physical Function in Old Age, *PLoS One*. 10 (2015) e0144048. <https://doi.org/10.1371/journal.pone.0144048>.
- [9] N. Veronese, B. Stubbs, S. Volpato, G. Zuliani, S. Maggi, M. Cesari, D.M. Lipnicki, L. Smith, P. Schofield, J. Firth, D. Vancampfort, A. Koyanagi, A. Pilotto, E. Cereda, Association Between Gait Speed With Mortality, Cardiovascular Disease and Cancer: A Systematic Review and Meta-analysis of Prospective Cohort Studies, *J. Am. Med. Dir. Assoc.* 19 (2018) 981-988.e7. <https://doi.org/10.1016/j.jamda.2018.06.007>.
- [10] R. Pavašini, J. Guralnik, J.C. Brown, M. di Bari, M. Cesari, F. Landi, B. Vaes, D. Legrand, J. Verghese, C. Wang, S. Stenholm, L. Ferrucci, J.C. Lai, A.A. Bartes, J. Espauella, M. Ferrer, J.-Y. Lim, K.E. Ensrud, P. Cawthon, A. Turusheva, E. Frolova, Y. Rolland, V. Lauwers, A. Corsonello, G.D. Kirk, R. Ferrari, S. Volpato, G. Campo, Short Physical Performance Battery and all-cause mortality: systematic review and meta-analysis, *BMC*

- Med. 14 (2016) 215. <https://doi.org/10.1186/s12916-016-0763-7>.
- [11] C.K. Suemoto, P. Ueda, H. Beltrán-Sánchez, M.L. Lebrão, Y.A. Duarte, R. Wong, G. Danaei, Development and Validation of a 10-Year Mortality Prediction Model: Meta-Analysis of Individual Participant Data From Five Cohorts of Older Adults in Developed and Developing Countries., *J. Gerontol. A. Biol. Sci. Med. Sci.* 00 (2016) 1–7. <https://doi.org/10.1093/gerona/glw166>.
- [12] F. de O.M. Maia, Y.A.O. Duarte, M.L. Lebrão, J.L.F. Santos, Risk factors for mortality among elderly people, *Rev. Saude Publica.* 40 (2006) 1049–1056. <https://doi.org/10.1590/S0034-89102006005000009>.
- [13] T.D.S. Alexandre, Y.A.D.O. Duarte, J.L.F. Santos, R. Wong, M.L. Lebrão, Sarcopenia according to the European Working Group on Sarcopenia in Older People (EWGSOP) versus dynapenia as a risk factor for mortality in the elderly, *J. Nutr. Health Aging.* (2014). <https://doi.org/10.1007/s12603-014-0450-3>.
- [14] C. de M. Nascimento, C. de Oliveira, J.O.A. Firmo, M.F. Lima-Costa, S.V. Peixoto, Prognostic value of disability on mortality: 15-year follow-up of the Bambuí cohort study of aging, *Arch. Gerontol. Geriatr.* 74 (2018) 112–117. <https://doi.org/10.1016/j.archger.2017.10.011>.
- [15] M.L. Lebrão, Y.A. de O. Duarte, J.L.F. Santos, N.N. da Silva, 10 Years of SABE Study: background, methodology and organization of the study, *Rev. Bras. Epidemiol.* 21 (2018). <https://doi.org/10.1590/1980-549720180002.supl.2>.
- [16] J.M. Guralnik, E.M. Simonsick, L. Ferrucci, R.J. Glynn, L.F. Berkman, D.G. Blazer, P.A. Scherr, R.B. Wallace, A Short Physical Performance Battery Assessing Lower Extremity Function: Association With Self-Reported Disability and Prediction of Mortality and Nursing Home Admission, *J. Gerontol.* 49 (1994) M85–M94.

<https://doi.org/10.1093/geronj/49.2.M85>.

- [17] K.T. Santos, M.H. Fernandes, J.A. Carneiro, R. da Silva Coqueiro, Motor performance tests as screening instruments for frailty in the older adults, *Appl. Nurs. Res.* 32 (2016) 80–84. <https://doi.org/10.1016/j.apnr.2016.06.003>.
- [18] M.G. Icaza, C. Albala, Minimental State Examination (MMSE) del estudio de demencia en Chile: análisis estadístico, *Investig. En Salud Pública - Doc. Técnicos.* 7 (1999) 1–18.
- [19] Pan-American Health Organization, Guía clínica para atención primaria a las personas adultas mayores, (2003).
- [20] Y. Nofuji, S. Shinkai, Y. Taniguchi, H. Amano, M. Nishi, H. Murayama, Y. Fujiwara, T. Suzuki, Associations of Walking Speed, Grip Strength, and Standing Balance With Total and Cause-Specific Mortality in a General Population of Japanese Elders, *J. Am. Med. Dir. Assoc.* 17 (2016) 184.e1-184.e7. <https://doi.org/10.1016/j.jamda.2015.11.003>.
- [21] L. Yu, P.A. Boyle, S.E. Leurgans, R.S. Wilson, D.A. Bennett, A.S. Buchman, Incident Mobility Disability, Mild Cognitive Impairment, and Mortality in Community-Dwelling Older Adults, *Neuroepidemiology.* 53 (2019) 55–62. <https://doi.org/10.1159/000499334>.
- [22] D.M. Peters, A. Middleton, J.W. Donley, E.L. Blanck, S.L. Fritz, Concurrent validity of walking speed values calculated via the GAITRite electronic walkway and 3 meter walk test in the chronic stroke population, *Physiother. Theory Pract.* 30 (2014) 183–188. <https://doi.org/10.3109/09593985.2013.845805>.
- [23] Y. Rolland, V. Lauwers-Cances, M. Cesari, B. Vellas, M. Pahor, H. Grandjean, Physical Performance Measures as Predictors of Mortality in a Cohort of Community-dwelling Older French Women, *Eur. J. Epidemiol.* 21 (2006) 113–122. <https://doi.org/10.1007/s10654-005-5458-x>.
- [24] N. Veronese, B. Stubbs, L. Fontana, C. Trevisan, F. Bolzetta, M. De Rui, L. Sartori, E.

- Musacchio, S. Zambon, S. Maggi, E. Perissinotto, M.C. Corti, G. Crepaldi, E. Manzato, G. Sergi, A Comparison of Objective Physical Performance Tests and Future Mortality in the Elderly People, *Journals Gerontol. Ser. A Biol. Sci. Med. Sci.* 72 (2016) glw139. <https://doi.org/10.1093/gerona/glw139>.
- [25] B. Olaya, M.V. Moneta, J. Doménech-Abella, M. Miret, I. Bayes, J.L. Ayuso-Mateos, J.M. Haro, Mobility Difficulties, Physical Activity, and All-cause Mortality Risk in a Nationally representative Sample of Older Adults, *Journals Gerontol. Ser. A.* 73 (2018) 1272–1279. <https://doi.org/10.1093/gerona/glx121>.
- [26] S.C. Webber, J.D. Ripat, N.S. Pachu, S.M. Strachan, Exploring physical activity and sedentary behaviour: perspectives of individuals with osteoarthritis and knee arthroplasty, *Disabil. Rehabil.* 42 (2020) 1971–1978. <https://doi.org/10.1080/09638288.2018.1543463>.
- [27] E.G. Heiland, C. Qiu, R. Wang, G. Santoni, Y. Liang, L. Fratiglioni, A.-K. Welmer, Cardiovascular Risk Burden and Future Risk of Walking Speed Limitation in Older Adults, *J. Am. Geriatr. Soc.* 65 (2017) 2418–2424. <https://doi.org/10.1111/jgs.15158>.
- [28] Q. Tian, Y. An, S.M. Resnick, S. Studenski, The relative temporal sequence of decline in mobility and cognition among initially unimpaired older adults: Results from the Baltimore Longitudinal Study of Aging, *Age Ageing.* 46 (2016) 445–451. <https://doi.org/10.1093/ageing/afw185>.
- [29] E. Frith, O. Addoh, J.R. Mann, B.G. Windham, P.D. Loprinzi, Individual and Combined Associations of Cognitive and Mobility Limitations on Mortality Risk in Older Adults, *Mayo Clin. Proc.* 92 (2017) 1494–1501. <https://doi.org/10.1016/j.mayocp.2017.06.019>.
- [30] J.H. Fong, Disability incidence and functional decline among older adults with major chronic diseases, *BMC Geriatr.* 19 (2019) 323. <https://doi.org/10.1186/s12877-019-1348-z>.
- [31] F.S. Thein, Y. Li, M.S.Z. Nyunt, Q. Gao, S.L. Wee, T.P. Ng, Physical frailty and cognitive

impairment is associated with diabetes and adversely impact functional status and mortality, *Postgrad. Med.* 130 (2018) 561–567.

<https://doi.org/10.1080/00325481.2018.1491779>.

- [32] R. Stewart, Cardiovascular Disease and Frailty: What Are the Mechanistic Links?, *Clin. Chem.* 65 (2019) 80–86. <https://doi.org/10.1373/clinchem.2018.287318>.
- [33] A.A. Roman Lay, C. Ferreira do Nascimento, F. Caba Burgos, A. del C. Larraín Huerta, R.E. Rivera Zeballos, V. Pantoja Silva, Y.A. de O. Duarte, Gender Differences between Multimorbidity and All-Cause Mortality among Older Adults, *Curr. Gerontol. Geriatr. Res.* 2020 (2020) 1–7. <https://doi.org/10.1155/2020/7816785>.
- [34] G.A. Wagner, M.L. Lebrão, Y.A. de O. Duarte, D.M.T. Zanetta, Alcohol Use among Older Adults: SABE Cohort Study, São Paulo, Brazil, *PLoS One.* 9 (2014) e85548. <https://doi.org/10.1371/journal.pone.0085548>.
- [35] B. Xi, S.P. Veeranki, M. Zhao, C. Ma, Y. Yan, J. Mi, Relationship of Alcohol Consumption to All-Cause, Cardiovascular, and Cancer-Related Mortality in U.S. Adults, *J. Am. Coll. Cardiol.* 70 (2017) 913–922. <https://doi.org/10.1016/j.jacc.2017.06.054>.
- [36] R. Ortolá, E. García-Esquinas, E. López-García, L.M. León-Muñoz, J.R. Banegas, F. Rodríguez-Artalejo, Alcohol consumption and all-cause mortality in older adults in Spain: an analysis accounting for the main methodological issues, *Addiction.* 114 (2019) 59–68. <https://doi.org/10.1111/add.14402>.
- [37] M. Inoue-Choi, L.M. Liao, C. Reyes-Guzman, P. Hartge, N. Caporaso, N.D. Freedman, Association of Long-term, Low-Intensity Smoking With All-Cause and Cause-Specific Mortality in the National Institutes of Health–AARP Diet and Health Study, *JAMA Intern. Med.* 177 (2017) 87–95. <https://doi.org/10.1001/jamainternmed.2016.7511>.
- [38] M.A. Beydoun, H.A. Beydoun, N. Mode, G.A. Dore, J.A. Canas, S.M. Eid, A.B.

Zonderman, Racial disparities in adult all-cause and cause-specific mortality among us adults: mediating and moderating factors, *BMC Public Health*. 16 (2016) 1113.

<https://doi.org/10.1186/s12889-016-3744-z>.

- [39] A. da Silva, T.E. da C. Rosa, L.E. Batista, S. Kalckmann, M.C.P. Louvison, D.S. da C. Teixeira, M.L. Lebrão, Racial inequities and aging: analysis of the 2010 cohort of the Health, Welfare and Aging Study (SABE), *Rev. Bras. Epidemiol.* 21 (2018) 1–14.
<https://doi.org/10.1590/1980-549720180004.supl.2>.
- [40] K. Latham, P.J. Clarke, G. Pavea, Social Relationships, Gender, and Recovery From Mobility Limitation Among Older Americans, *Journals Gerontol. Ser. B Psychol. Sci. Soc. Sci.* 70 (2015) 769–781. <https://doi.org/10.1093/geronb/gbu181>.

Declarations

Funding: This work was supported by the Brazilian National Research Council (CNPq) [grant number 152494/2016-2].

Conflicts of interest/Competing interests: On behalf of all authors, the corresponding author states that there is no conflict of interest.

Availability of data and material: Not applicable.

Code availability: Upon request.

Authors' contributions: CF do Nascimento was responsible for study conception and design, statistical analysis, interpretation of data, and drafting of the manuscript. AA Roman Lay participated in study concept, acquisition of data, analysis and interpretation of data. YAO Duarte participated in study concept and design, acquisition and interpretation of data. ADP Chiavegatto Filho responsible for study conception and design, data analysis, drafting of the manuscript. All authors contributed to revision of the article and approved the final version.

Ethics approval: This study received approval from the Human Research Ethics Committee of the School of Public Health/University of São Paulo (protocol number 315/99, 83/06, and 2044).

Consent to participate: All participants gave written informed consent.

Figure 1. Flow diagram of the study.

Table 1.

Sample distribution according to gait speed and chair stand test (%), n=1,411.

Variables	Total sample	Gait speed			Chair stand test		
		Faster	Slower	Unable to perform	Faster	Slower	Unable to perform
Age (mean/SD)	69.6 (7.5)	67.8(5.5)	69.9(7.6)	73.2(10.3)	68.2(5.5)	69.1(7.4)	75.1(9.4)
Gender							
Female	59.4	25.9	63.8	10.3	31.2	52.8	16.0
Male	40.6	39.9	50.0	10.1	42.5	46.0	11.5
Living alone ^a							
Yes	13.2	18.7	72.6	8.7	36.7	49.9	13.4
No	86.8	33.6	55.9	10.5	30.1	50.6	19.3
Education (years) ^a							
None	15.7	18.4	65.6	16.0	21.2	56.9	21.9
1 – 3	26.5	23.7	65.8	10.6	33.9	52.0	14.1
4 – 7	38.6	34.5	57.1	8.3	38.0	49.7	12.3
>8	19.2	47.5	43.2	9.3	46.2	41.9	12.0
Race/skin color							
White	63.4	33.5	56.0	10.5	35.6	49.2	15.2
Black or mixed	27.5	24.6	65.1	10.3	34.4	52.5	13.0
Other	9.1	39.4	52.5	8.1	41.2	48.8	10.1
Multimorbidity							
Yes	55.6	26.1	61.8	12.2	29.8	51.7	18.5
No	44.4	38.5	53.6	7.8	43.2	48.0	8.7
Alcohol intake ^a							
Never	69.2	25.3	63.0	11.8	31.5	51.2	17.3
up to 1 day/week	16.9	46.8	48.9	4.3	45.5	48.6	5.9
2 days/week or more	13.9	44.3	45.9	9.8	45.3	46.3	8.5
Smoking status							
Current smoker	14.0	30.4	58.3	11.3	38.9	48.1	13.0
Have ever smoked	34.0	29.1	60.7	10.2	37.6	46.7	15.6
Never	52.0	33.5	56.4	10.0	33.7	52.8	13.5
Cognitive status							
Impaired	12.2	11.3	59.4	29.2	16.2	47.0	36.8
Preserved	87.8	34.4	58.0	7.6	38.5	50.5	11.0
Body Mass Index ^a							
Low	23.0	28.9	56.5	14.6	31.5	49.0	19.5
Normal	42.0	36.7	56.6	6.7	42.5	47.9	9.6
High	11.3	30.2	60.0	9.8	35.4	53.5	11.0
Obesity	22.1	27.5	66.2	6.3	30.0	57.0	12.9
10-year mortality							
Yes	25.9	21.0	60.9	18.1	25.1	48.9	26.1

No	74.1	35.3	57.2	7.5	39.5	50.5	10.0
Gait speed	0.79 (0.26)	31.6	58.2	10.2	-	-	-
Chair stand test	16.06 (5.33)	-	-	-	35.8	14.2	50.1

Notes: ^a Number of missing values for the following variables: 25 (BMI), 4 (education), 4 (alcohol intake), 3 (living alone).

Table 2.

Hazard ratios (HR) and 95% confidence intervals (CI) for 10-year mortality according to baseline gait speed and time to complete the chair stand test, n=1,375^a.

	Variables	Model 1 ^b			Model 2 ^c			Model 3 ^d			Model 4 ^e		
		HR	95%CI		HR	95%CI		HR	95%CI		HR	95%CI	
All-cause mortality	Gait speed (m/s)	0.52	(0.30;0.88)	*	0.59	(0.35;1.00)		0.67	(0.40;1.13)		0.68	(0.40;1.15)	
	Chair stand test (s)	1.03	(1.01;1.05)	**	1.03	(1.01;1.05)	**	1.03	(1.00;1.05)	*	1.03	(1.00;1.05)	*
	Gait speed												
	Faster	1.00			1.00			1.00			1.00		
	Slower	1.47	(1.09;1.99)	*	1.44	(1.06;1.94)	*	1.19	(0.91;1.56)		1.33	(0.98;1.82)	
	Not able	2.35	(1.64;3.39)	***	2.24	(1.54;3.25)	***	1.79	(1.20;2.69)	**	1.80	(1.20;2.70)	**
	Chair stand test												
	Faster	1.00			1.00			1.00			1.00		
	Slower	1.42	(1.07;1.88)	*	1.38	(1.04;1.82)	*	1.39	(1.05;1.85)	*	1.39	(1.05;1.85)	*
	Not able	2.09	(1.52;2.88)	***	2.01	(1.46;2.78)	***	1.69	(1.19;2.40)	**	1.71	(1.21;2.42)	**
Mortality by diseases of the circulatory system	Gait speed (m/s)	0.33	(0.12;0.87)	*	0.40	(0.16;0.99)	*	0.40	(0.16;1.02)		0.42	(0.16;1.06)	
	Chair stand test (s)	1.03	(0.99;1.06)		1.02	(0.99;1.05)		1.02	(0.99;1.05)		1.02	(0.99;1.06)	
	Gait speed												
	Faster	1.00			1.00			1.00			1.00		
	Slower	1.83	(1.10;3.05)	*	1.74	(1.04;2.90)	*	1.70	(1.01;2.84)	*	1.64	(0.97;2.77)	
	Not able	3.29	(1.81;5.98)	***	3.09	(1.69;5.64)	***	1.67	(1.02;2.71)	**	2.44	(1.30;4.56)	**
	Chair stand test												
	Faster	1.00			1.00			1.00			1.00		
	Slower	1.34	(0.86;2.09)		1.26	(0.81;1.97)		1.30	(0.83;2.03)		1.28	(0.82;2.00)	
	Not able	2.75	(1.64;4.61)	***	2.52	(1.52;4.18)	***	2.14	(1.23;3.70)	**	2.14	(1.25;3.65)	**
Mortality by diseases of the respiratory system	Gait speed (m/s)	0.64	(0.23;1.77)		0.82	(0.27;2.44)		1.22	(0.47;3.16)		1.24	(0.43;3.56)	
	Chair stand test (s)	1.03	(0.98;1.08)		1.02	(0.97;1.07)		1.02	(0.96;1.08)		1.02	(0.95;1.08)	
	Gait speed												
	Faster	1.00			1.00			1.00			1.00		
	Slower	0.86	(0.46;1.59)		0.81	(0.42;1.57)		0.65	(0.34;1.23)		0.66	(0.33;1.30)	
	Not able	1.18	(0.61;2.29)		1.01	(0.48;2.11)		0.75	(0.37;1.53)		0.72	(0.35;1.51)	
	Chair stand test												
	Faster	1.00			1.00			1.00			1.00		
	Slower	1.28	(0.64;2.54)		1.23	(0.62;2.46)		1.21	(0.57;2.53)		1.23	(0.58;2.60)	
	Not able	2.56	(1.25;5.24)	*	2.45	(1.15;5.23)	*	1.96	(0.92;4.17)		2.04	(0.94;4.44)	
Mortality by neoplasms	Gait speed (m/s)	0.42	(0.15;1.20)		0.46	(0.16;1.26)		0.40	(0.13;1.20)		0.39	(0.13;1.18)	
	Chair stand test (s)	1.04	(1.00;1.08)	*	1.03	(0.99;1.08)		1.04	(1.00;1.08)	*	1.04	(0.99;1.08)	
	Gait speed												
	Faster	1.00			1.00			1.00			1.00		
	Slower	1.92	(1.00;3.65)	*	1.97	(1.05;3.71)	*	1.84	(0.96;3.54)		1.98	(1.02;3.86)	*
	Not able	1.19	(0.43;3.30)		1.14	(0.41;3.15)		1.09	(0.39;3.06)		1.10	(0.39;3.10)	
	Chair stand test												
	Faster	1.00			1.00			1.00			1.00		
	Slower	1.61	(0.88;2.95)		1.57	(0.86;2.84)		1.65	(0.90;3.03)		1.61	(0.88;2.93)	

	Not able	0.71 (0.31;1.59)	0.69 (0.30;1.58)	0.64 (0.28;1.48)	0.64 (0.27;1.50)
--	----------	------------------	------------------	------------------	------------------

^aFrom 1,114 individuals, 36 were excluded due to missing values in some variables. ^bAdjusted by sex and age. ^cAdjusted by sex, age and socioeconomic variables. ^dAdjusted by sex, age and health variables. ^eAdjusted by sex, age, socioeconomic and health variables. *p<0,05, **p<0,01, ***p<0,001.

Table 3.

Hazard ratios (HR) and 95% confidence intervals (CI) for 10-year mortality according to baseline socioeconomic and health variables stratified by categories of chair stand test, n=1,411.

Variables	Best performance (n=411)			Worst performance (n=698)			Not able (n=302)		
	HR	(95% CI)		HR	(95% CI)		HR	(95% CI)	
Age	1.11	(1.07;1.14)	***	1.09	(1.07;1.11)	***	1.04	(1.02;1.07)	**
Gender Female	0.41	(0.23;0.73)	**	0.56	(0.39;0.81)	**	0.52	(0.34;0.79)	**
Race/skin color (ref.: white)									
Black or mixed	0.76	(0.43;1.36)		1.73	(1.20;2.49)	**	0.62	(0.41;0.95)	*
Other	0.83	(0.39;1.77)		1.21	(0.67;2.18)		1.13	(0.62;2.05)	
Multimorbidity	1.05	(0.67;1.65)		1.10	(0.78;1.55)		1.75	(1.15;2.67)	**
Cognitive impairment	1.20	(0.53;2.74)		1.89	(1.26;2.83)	**	2.23	(1.49;3.33)	***
Body Mass Index (Ref.: Normal)									
Low	1.34	(0.77;2.34)		1.46	(0.99;2.15)		1.48	(0.99;2.20)	
High	0.93	(0.40;2.18)		1.41	(0.83;2.38)		0.49	(0.19;1.25)	
Obesity	1.20	(0.61;2.36)		1.22	(0.77;1.93)		0.85	(0.46;1.56)	
Alcohol intake (Ref.: Never)									
until 1 day/week	0.35	(0.16;0.77)	**	0.81	(0.51;1.28)		0.78	(0.31;1.96)	
2 days/week or more	0.62	(0.32;1.20)		1.16	(0.67;2.02)		0.58	(0.32;1.04)	
Smoking status (Ref.: Never)									
Current smoker	2.29	(1.24;4.22)	**	2.37	(1.39;4.06)	**	0.65	(0.33;1.32)	
Have ever smoked	1.20	(0.70;2.06)		1.33	(0.89;1.97)		0.74	(0.49;1.12)	
Living alone	0.53	(0.25;1.11)		1.37	(0.91;2.07)		1.52	(0.97;2.36)	
Years of education (ref: None)									
1 – 3	0.58	(0.28;1.21)		0.77	(0.50;1.19)		0.77	(0.47;1.28)	
4 – 7	0.91	(0.47;1.73)		1.19	(0.76;1.85)		0.95	(0.57;1.58)	
>8	0.71	(0.35;1.43)		0.77	(0.39;1.49)		0.62	(0.31;1.23)	
Global Schoenfeld test (p-value)		0.621			0.350			0.253	

*p<0.05, **p<0.01, ***p<0.001.

Supplemental Digital Content

Supplementary Table 1 (Supplementary_revised.doc)

Supplementary Table 1: Distribution of sample according to 3 most frequent ICD-10's chapters.

Diseases of the circulatory system (I00-I99)			Neoplasms (C00-D94)		
Codes	Diseases	n	Codes	Diseases	n
I10	Essential (primary) hypertension	3	C02	Malignant neoplasm of other and unspecified parts of tongue	1
I11	Hypertensive heart disease	15	C04	Malignant neoplasm of floor of mouth	1
I12	Hypertensive renal disease	2	C07	Malignant neoplasm of parotid gland	1
I13	Hypertensive heart and renal disease	2	C15	Malignant neoplasm of esophagus	4
I21	Acute myocardial infarction	50	C16	Malignant neoplasm of stomach	1
I24	Other acute ischemic heart diseases	1	C18	Malignant neoplasm of colon	1
I25	Chronic ischemic heart disease	26	C20	Malignant neoplasm of rectum	3
I26	Pulmonary embolism	10	C21	Malignant neoplasm of anus and anal canal	1
I34	Nonrheumatic mitral valve disorders	1	C22	Malignant neoplasm of liver and intrahepatic bile ducts	7
I35	Nonrheumatic aortic valve disorders	1	C23	Malignant neoplasm of gallbladder	1
I36	Nonrheumatic tricuspid valve disorders	1	C24	Malignant neoplasm of other and unspecified parts of biliary tract	3
I42	Cardiomyopathy	9	C25	Malignant neoplasm of pancreas	4
I44	Atrioventricular and left bundle-branch block	1	C26	Malignant neoplasm of other and ill-defined digestive organs	1
I49	Other cardiac arrhythmias	2	C32	Malignant neoplasm of larynx	3
I50	Heart failure	15	C34	Malignant neoplasm of bronchus and lung	7
I51	Complications and ill-defined descriptions of heart disease	1	C38	Malignant neoplasm of heart, mediastinum and pleura	1
I61	Intracerebral hemorrhage	4	C40	Malignant neoplasm of bone and articular cartilage of limbs	1
I63	Cerebral infarction	15	C43	Malignant melanoma of skin	1
I64	Stroke, not specified as hemorrhage or infarction	16	C44	Other malignant neoplasms of skin	1
I67	Other cerebrovascular diseases	4	C50	Malignant neoplasm of breast	7
I69	Sequelae of cerebrovascular disease	11	C52	Malignant neoplasm of vagina	1
I71	Aortic aneurysm and dissection	6	C53	Malignant neoplasm of cervix uteri	1
I73	Other peripheral vascular diseases	1	C54	Malignant neoplasm of corpus uteri	4
I74	Arterial embolism and thrombosis	1	C55	Malignant neoplasm of uterus, part unspecified	1
I80	Phlebitis and thrombophlebitis	1	C56	Malignant neoplasm of ovary	2
Total		199	C57	Malignant neoplasm of other and unspecified female genital organs	2

Diseases of the respiratory system (J00-J99)					
Codes	Diseases	n			
J15	Bacterial pneumonia, not elsewhere classified	2	C61	Malignant neoplasm of prostate	11
J18	Pneumonia, organism unspecified	56	C63	Malignant neoplasm of other and unspecified male genital organs	1
J40	Bronchitis, not specified as acute or chronic	1	C64	Malignant neoplasm of kidney, except renal pelvis	3
J43	Emphysema	4	C68	Malignant neoplasm of other and unspecified urinary organs	1
J44	Other chronic obstructive pulmonary disease	28	C71	Malignant neoplasm of brain	2
J45	Asthma	1	C76	Malignant neoplasm of other and ill-defined sites	1
J64	Unspecified pneumoconiosis	1	C79	Secondary malignant neoplasm of other and unspecified sites	1
J69	Pneumonitis due to solids and liquids	7	C80	Malignant neoplasm, without specification of site	1
J84	Other interstitial pulmonary diseases	2	C85	Other and unspecified types of non-Hodgkin lymphoma	1
J90	Pleural effusion, not elsewhere classified	1	C91	Lymphoid leukemia	1
J98	Other respiratory disorders	6	C92	Myeloid leukemia	1
Total		109	C95	Leukemia of unspecified cell type	1
			D13	Benign neoplasm of other and ill-defined parts of digestive system	1
			D18	Hemangioma and lymphangioma, any site	1
			I		88

4.3ARTIGO 3

Cause-specific mortality prediction in older residents of São Paulo, Brazil: A machine learning approach

Publicado na *Age and Ageing* (Qualis A1).

Authors: Carla Ferreira do Nascimento^{1*}; Hellen Geremias dos Santos²; André Filipe de Moraes Batista¹; Alejandra Andrea Roman Lay³; Yeda Aparecida Oliveira Duarte⁴; Alexandre Dias Porto Chiavegatto Filho¹.

¹ School of Public Health, University of São Paulo, São Paulo, Brazil

² Carlos Chagas Institute, Oswaldo Cruz Foundation, Curitiba, Brazil

³ Faculty of Health Sciences, University of Tarapacá, Arica, Chile

⁴ School of Nursing, University of São Paulo, São Paulo, Brazil

*** Corresponding author:**

Carla Ferreira do Nascimento, Department of Epidemiology, School of Public Health, University of São Paulo, Avenida Doutor Arnaldo, 715, 1º andar, CEP: 01246-904, Telephone number: 55 (11)3061-7737. E-mail: carlafn@usp.br

Cause-specific mortality prediction in older residents of São Paulo, Brazil: A machine learning approach

Abstract

Background: Populational ageing has been increasing in a remarkable rate in developing countries. In this scenario, preventive strategies could help to decrease the burden of higher demands for healthcare services. Machine learning algorithms have been increasingly applied for identifying priority candidates for preventive actions, presenting a better predictive performance than traditional parsimonious models.

Methods: Data was collected from the Health, Well Being and Aging (SABE) Study, a representative sample of older residents of São Paulo, Brazil. Machine learning algorithms were applied to predict death by diseases of respiratory system (DRS), diseases of circulatory system (DCS), neoplasms, and other specific causes within 5 years, using socioeconomic, demographic and health features. The algorithms were trained in a random sample of 70% of subjects, and then tested in the other 30% unseen data.

Results: The outcome with highest predictive performance was death by DRS (AUC-ROC=0.89), followed by the other specific causes (AUC-ROC=0.87), DCS (AUC-ROC=0.67) and neoplasms (AUC-ROC=0.52). Among only the 25% of individuals with the highest predicted risk of mortality from DRS were included 100% of the actual cases. The machine learning algorithms with the highest predictive performance were light gradient boosted machine and extreme gradient boosting.

Conclusions: The algorithms had a high predictive performance for DRS, but lower for DCS and neoplasms. Mortality prediction with machine learning can improve clinical decisions especially regarding targeted preventive measures for older individuals.

Keywords: Machine learning, mortality, prediction modeling

Introduction

Populational ageing has been increasing throughout the world, especially in developing countries[1]. Recent projections indicate a fourfold growth in the older population from 2015 to 2050 in several of these countries, including Brazil[2]. In 30 years, the Brazilian population aged 60 years and more increased 285% according to last census data from 2010[3]. This growth of the older population has occurred in a context of large economic disparities in addition to the burden of noncommunicable diseases, injuries, violence and infectious diseases[4].

Preventive strategies focused on vulnerable populations could help to decrease the growing demands for healthcare services in developing countries[1]. Machine learning (ML) algorithms have been increasingly applied for identifying priority candidates for preventive actions, and have been shown to present a better predictive ability than risk scores from traditional parsimonious models[5,6].

Mortality prediction studies have historically focused on understanding and identifying risk factors, in order to promote targeted interventions on specific characteristics[7,8]. However, this is frequently concomitant with a low predictive performance, as parsimonious models frequently lack the ability to model the complex interactions of factors that increase mortality risk[8,9]. With the recent growth in data availability, it has become feasible to implement more complex models, which are less suitable for inferential problems, but that have a greater predictive potential to assist with more assertive clinical decisions regarding individual mortality risk[10].

The aim of this study is to compare the performance of popular machine learning algorithms in predicting cause-specific mortality risk according to ICD-10 (10th Revision of International Classification of Diseases) chapters, in older adults from São Paulo, Brazil.

Methods

Data was collected from SABC (Health, Well-being and Aging Study), a multiple cohort study representative of older residents (≥ 60 years old) of the urban area of municipality of São Paulo, Brazil. Details of SABC have been published elsewhere[11]. In brief, subjects were selected by clustered sampling from an initial sample of 72 census tracts of the municipality of São Paulo, selected by probability proportional to size approach. The first wave of SABC was conducted in 2000 and was composed of 2,143 older adults. The subsequent waves were conducted in 2006, 2010 and 2015, and in each of them the previous cohorts were revisited and a new probabilistic cohort, composed of 60-64 years-old individuals, was added to the sample[11]. The Supplementary Figure S1 summarize the sample design of SABC Study.

All subjects signed a statement of informed consent and individual anonymity was preserved. The research project received approval from the Human Research Ethics Committee of the School of Public Health/University of São Paulo (protocol number 315/99, 83/06 and 2044).

For the present study, we analyzed only the sample composed by the 2006 wave ($n=1,412$) and the sample added in 2010 ($n=355$), totaling 1767 individuals (see Supplementary Figure S1). The outcome of interest was the primary cause of death, i.e., the condition or injury that initiated the train of events leading directly to death, up to five years after the interview, according to chapters of the International Classification of Diseases, 10th revision (ICD-10).

The date and the primary cause of death of participants were obtained from a probabilistic linkage of the SABC database with official municipality mortality records. We performed a multiclass classification analysis considering the following categories of outcome: mortality from diseases of the circulatory system, DCS (ICD-10: I00-I99), from diseases of the respiratory system, DRS (J00-J99), from neoplasms (C00-D48), and from other specific causes.

Potential predictors of mortality risk were selected according to previous studies in the field[7,12]. Individual data was collected from a questionnaire administered by a trained health professional and composed of demographic variables (age, gender, years of schooling, income sufficiency, living alone and race/skin color), health variables (self-rated health, smoking and alcohol consumption per week), cognitive impairment (evaluated by the modified version of Mini-Mental State Examination[13]), self-reported non-communicable diseases (diabetes mellitus, respiratory diseases, cardiovascular diseases, cerebrovascular diseases, hypertension, arthrosis or other joint disease, mental disorders), mobility-related variables (occurrence of any fall in last 12 months, feel able to perform the physical tests and feel safe to stand up and sit down five times, average daily sitting time) and physical measures (average grip strength, body mass index and the tasks of the Short Physical Performance Battery[14]).

In order to assess the predictive performance of the machine learning models in new unseen data, we randomly divided the dataset into training (70%) and test set (30%). The numeric features were standardized by the z-score. Missing values of numerical variables were imputed by the median and categorical variables by the mode. Both standardization and imputation parameters were obtained from the training set, and then applied to the test set. We also resampled the training set using different methods: the random oversampling method, which randomly duplicates observations from the minority class, and SMOTE (Synthetic Minority Oversampling Technique). These strategies aim to minimize the impact of unbalanced data on the performance of the algorithms. After resampling, the final size of the train set was 4,015 observations.

A total of 14 popular machine learning algorithms were trained with 10-fold cross-validation, using the one-versus-all multiclass classification method: random forest, quadratic discriminant analysis, extra trees classifier, light gradient boosting machine, catboost, gradient boosting trees, extreme gradient boosting, k-nearest neighbors, decision trees, ada boost,

logistic regression, ridge logistic regression, linear discriminant analysis, support vector machines and naive bayes. The results for the algorithms on the train set are showed in Supplementary Table S1.

The five algorithms with best prediction on train set were selected. The confusion matrix was obtained for the test set. Moreover, because of the unbalanced nature of the dataset, we also calculated the actual total cases included among only the 25% individuals with highest probability as attributed by the algorithms. We also obtained the sensitivity and specificity for the optimal threshold for each class individually. The contribution of each variable to the predictive models was accessed by the SHAP (SHapley Additive exPlanations) values[15].

All the analyses were performed in Python. For training the machine learning algorithms we used the library LABDAPS MLFlow (Machine Learning Workflow by Big Data and Predictive Analytics in Healthcare Lab - University of São Paulo [LABDAPS-USP]), a customized version of PyCaret[16].

Results

Of the 1,767 individuals included in the sample, 62% were female, and the mean age was 72 years. Regarding the outcomes, 104 (5.9%) died by diseases of circulatory system (DCS), 58 (3.3%) by diseases of respiratory system (DRS), 59 (3.3%) by neoplasms, and 398 (22,5%) by the other specific causes of death up to 5 years after the interview, leading to a highly unbalanced data. The distribution and description of the sample according to predictors and outcomes are presented in Supplementary Table S2 and Table 1.

The algorithm with the best performance was the Light Gradient Boosted Machine (LGBM), followed by the Extreme Gradient Boosted (XGB), and the specific outcome with highest overall performance was death by DRS, with an AUC-ROC of 0.89, followed by death by other specific causes (AUC-ROC of 0.87) (Figure 1). An optimal threshold was able to

identify 88% of deaths by DRS, with a specificity of 77%, using the LGBM algorithm. For deaths by DCS and neoplasms, the AUC-ROC was 0.67 and 0.52, respectively, as showed in Table 2. The metrics for the two best algorithms of each outcome are presented in Table 2. The AUC-ROC of the other three algorithms with best prediction are presented in Supplementary Figure S2.

Due to the impact of class imbalance on the calibration of the algorithm, we also ranked the individuals according to probabilities attributed by the algorithms of each class, and analyzed the total true cases among the 25% individuals with the highest probability attributed by the algorithms. Using the XGB algorithm we found that among the 25% individuals with highest probability all actual cases were included. For deaths by other specific causes, the algorithms were also able to include all true cases within the 25%. The results for the other classes are presented in Table 2.

We then tested the importance of each variable for the four outcomes according to the SHAP values. The 5 variables that most contributed to predict death by DRS using the LGBM algorithm were age, BMI, presence of self-report lung disease, sitting time and female gender (Figure 2). For DCS, the variables were age, BMI, sitting time, diabetes and to be unable to walk; for neoplasm they were age, BMI, sitting time, grip strength and female gender; and for the other specific causes, were age, sitting time, grip strength, race black or mixed and BMI.

Discussion

The potential applications of machine learning for ageing research are promising and growing[10,17]. These techniques have the potential to guide health professionals in making better clinical decisions and planning preventive strategies by predicting an early risk of death[17–19]. This study found that mortality from DRS can be predicted with good performance by ML algorithms using sociodemographic, self-reported health and physical data.

On the other hand, the algorithms were not able to predict mortality by DCS and neoplasm with the same performance.

Other studies have tested the performance of machine learning to predict overall mortality. Rose (2013) compared the predictive performance of machine learning algorithms to predict mortality in 2,066 older adults from California and observed that an ensemble method was the most efficient. More recently, Wallace et al (2019) analyzed the performance of a multidimensional self-reported sleep domain to predict cardiovascular and all-cause mortality in 8,668 older individuals with machine learning[19]. Differently from the present study, the authors focused on only one machine learning model, the survival random forest. Other adverse events have also been analyzed in geriatric studies, such as risk of falls[20] or fall injuries[21] that may also contribute to early preventive strategies.

Our study found that machine learning algorithms can help to identify community-dwelling older individuals with high risk to die by respiratory diseases, using demographic, self-reported health and physical measures. The use of artificial intelligence to improve decisions in respiratory medicine have been promising[22]. There are evidences, for example, that machine learning algorithms are able to predict Chronic Obstructive Pulmonary Disease (COPD) diagnosis and prognosis[22]. However, to the best of our knowledge, there are no studies that analyzed the performance of machine learning algorithms to predict mortality by respiratory diseases in older adults.

The performance of the algorithms in predicting mortality by DCS was less accurate than by DRS. This is probably due to the fact that the features included in the questionnaires are not as important. However, there is a growing number of publications on the use of artificial intelligence in cardiology. Recent studies have demonstrated the application of algorithms to predict mortality from cardiovascular disease[19], to predict death in patients undergoing cardiovascular surgery[23], and to predict mortality in patients with suspected coronary artery

disease[24]. An analysis performed in a community-based cardiovascular disease cohort found an AUC-ROC higher than 0.80 when predicting death by cardiovascular diseases and coronary heart disease. However, these studies included blood measurements, such as cholesterol and triglycerides, which are not available from questionnaire data[9].

Even though the use of machine learning for diagnosis and prognosis of cancer is also increasing[25,26], prediction of cancer mortality in community-dwelling individuals is still scarce. A recent study applied machine learning models to predict the risk of an early death in older individuals diagnosed with cancer, obtaining an AUC-ROC between 0.68 to 0.83, depending on the variables included and the selection of the algorithm[27]. Our results did not achieve a high performance in predicting death by neoplasms in older adults. We suspect that by including other measures, especially genetic data and bioimaging exams, our predictive performance would be considerably higher[26]. Furthermore, the second chapter of ICD-10 (i.e. neoplasms), includes all types of tumors and it is known that different types and locations have different risk factors[28].

The performance of the algorithms depends heavily on the presence of relevant predictors. The most important variables for predicting death by DRS, according to the SHAP values, were age, cognitive impairment, BMI, gender and others communicable diseases and physical measures. There are evidences that these variables are associated to increased risk of respiratory diseases incidence and mortality [7,29,30]. Although there is a plausibility in the relationship of these variables with the outcome, it is important to be consider that the importance of the variables, as measured by the SHAP values (Figures 2), does not allow for causal inferences[15]. It is interesting to note, however, the presence of variables related to socioeconomic status, i.e., race/skin color and schooling, among the 10 most important in predicting death from other specific causes. These other causes include infectious diseases and external causes, which are highly influenced by socioeconomic aspects[4].

This study has a few limitations. First, the imbalanced class of outcomes may have limited the performance of algorithms, as shown in previous machine learning analyzes[27]. Second, grouping causes of death by ICD-10 chapters, which include many categories of diseases, could also compromise the ability of the algorithms to find specific patterns in the data. However, separating the causes of death by more restrictive groups of diseases would further increase the unbalancing. Third, most predictors were self-reported, and therefore amenable to memory bias. Cognitive decline was screened by the Mini-mental State Examination test, and if necessary, a proxy close to the participant answered the questions. At last, even though the variables included as predictors are very straightforward to measure with a structured questionnaire, which helps with the future replication of the study in remote areas of developing countries, it may also hinder the predictive ability of the models.

To our knowledge, this is the first study to test the performance of machine learning algorithms to predict cause-specific mortality in a representative sample. We found that the algorithms had a high predictive performance for DRS, but lower for DCS and neoplasms. As population ageing continues its exponential growth in developing countries, mortality prediction with machine learning could contribute to better clinical decisions especially in remote areas and to the planning of targeted health policies for older individuals.

Funding

This work was supported by the Brazilian National Research Council (CNPq), grant number 152494/2016-2.

References

1. World Health Organization. *World Report on Ageing and Health*. Geneva, 2015.
2. He W, Goodkind D, Kowal P. *An Aging World : 2015 International Population Reports*.

Washington, DC, 2016.

3. Ministério da Saúde. Departamento de Informática do Sistema Único de Saúde (DATASUS). 2020.

4. Marinho F, de Azeredo Passos VM, Carvalho Malta D *et al.* Burden of disease in Brazil, 1990–2016: a systematic subnational analysis for the Global Burden of Disease Study 2016. *Lancet* 2018;**392**:760–75.

5. Kan HJ, Kharrazi H, Chang H-Y *et al.* Exploring the use of machine learning for risk adjustment: A comparison of standard and penalized linear regression models in predicting health care costs in older adults. Stiglic G (ed.). *PLoS One* 2019;**14**:e0213258.

6. Hatton CM, Paton LW, McMillan D *et al.* Predicting persistent depressive symptoms in older adults: A machine learning approach to personalised mental healthcare. *J Affect Disord* 2019;**246**:857–60.

7. Suemoto CK, Ueda P, Beltrán-Sánchez H *et al.* Development and Validation of a 10-Year Mortality Prediction Model: Meta-Analysis of Individual Participant Data From Five Cohorts of Older Adults in Developed and Developing Countries. *J Gerontol A Biol Sci Med Sci* 2016;**00**:1–7.

8. Sultana J, Fontana A, Giorgianni F *et al.* Can information on functional and cognitive status improve short-term mortality risk prediction among community-dwelling older people? A cohort study using a UK primary care database. *Clin Epidemiol* 2017;**Volume 10**:31–9.

9. Wang H, Li Y, Ning H *et al.* Using machine learning to integrate socio-behavioral factors in predicting cardiovascular-related mortality risk. *Stud Health Technol Inform* 2019;**264**:433–7.

10. Schwalbe N, Wahl B. Artificial intelligence and the future of global health. *Lancet* 2020;**395**:1579–86.

11. Lebrão ML, Duarte YA de O, Santos JLF *et al.* 10 Anos do Estudo SABE: antecedentes,

metodologia e organização do estudo. *Rev Bras Epidemiol* 2018;**21**, DOI: 10.1590/1980-549720180002.supl.2.

12. Nofuji Y, Shinkai S, Taniguchi Y *et al.* Associations of Walking Speed, Grip Strength, and Standing Balance With Total and Cause-Specific Mortality in a General Population of Japanese Elders. *J Am Med Dir Assoc* 2016;**17**:184.e1-184.e7.

13. Icaza MG, Albala C. Minimental State Examination (MMSE) del estudio de dementia en Chile: análisis estatístico. 1999:1–18.

14. Guralnik JM, Simonsick EM, Ferrucci L *et al.* A Short Physical Performance Battery Assessing Lower Extremity Function: Association With Self-Reported Disability and Prediction of Mortality and Nursing Home Admission. *J Gerontol* 1994;**49**:M85–94.

15. Lundberg SM, Lee S-I. A Unified Approach to Interpreting Model Predictions. *Adv Neural Inf Process Syst* 2017:4765–4774.

16. PyCaret.org. PyCaret. *PyCaret version 100* 2020.

17. Odden MC, Melzer D. Machine Learning in Aging Research. *Journals Gerontol Ser A* 2019;**74**:1901–2.

18. Rose S. Mortality risk score prediction in an elderly population using machine learning. *Am J Epidemiol* 2013;**177**:443–52.

19. Wallace ML, Buysse DJ, Redline S *et al.* Multidimensional Sleep and Mortality in Older Adults: A Machine-Learning Comparison With Other Risk Factors. Melzer D (ed.). *Journals Gerontol Ser A* 2019;**74**:1903–9.

20. Ye C, Li J, Hao S *et al.* Identification of elders at higher risk for fall with statewide electronic health records and a machine learning algorithm. *Int J Med Inform* 2020;**137**:104105.

21. Speiser JL, Callahan KE, Houston DK *et al.* Machine Learning in Aging: An Example of Developing Prediction Models for Serious Fall Injury in Older Adults. Melzer D (ed.).

Journals Gerontol Ser A 2020;**XX**:1–8.

22. Mekov E, Miravittles M, Petkov R. Artificial intelligence and machine learning in respiratory medicine. *Expert Rev Respir Med* 2020;**14**:559–64.

23. Allyn J, Allou N, Augustin P *et al.* A Comparison of a Machine Learning Model with EuroSCORE II in Predicting Mortality after Elective Cardiac Surgery: A Decision Curve Analysis. Parolari A (ed.). *PLoS One* 2017;**12**:e0169772.

24. Motwani M, Dey D, Berman DS *et al.* Machine learning for prediction of all-cause mortality in patients with suspected coronary artery disease: A 5-year multicentre prospective registry analysis. *Eur Heart J* 2017;**38**:500–7.

25. Elfiky AA, Pany MJ, Parikh RB *et al.* Development and Application of a Machine Learning Approach to Assess Short-term Mortality Risk Among Patients With Cancer Starting Chemotherapy. *JAMA Netw Open* 2018;**1**:e180926.

26. Cruz JA, Wishart DS. Applications of Machine Learning in Cancer Prediction and Prognosis. *Cancer Inform* 2006;**2**:117693510600200.

27. Sena GR, Lima TPF, Mello MJG *et al.* Developing Machine Learning Algorithms for the Prediction of Early Death in Elderly Cancer Patients: Usability Study. *JMIR Cancer* 2019;**5**:e12163.

28. Azevedo E Silva G, De Moura L, Curado MP *et al.* The fraction of cancer attributable to ways of life, infections, occupation, and environmental agents in Brazil in 2020. *PLoS One* 2016;**11**:1–13.

29. Fogg C, Meredith P, Bridges J *et al.* The relationship between cognitive impairment, mortality and discharge characteristics in a large cohort of older adults with unscheduled admissions to an acute hospital: a retrospective observational study. *Age Ageing* 2017;**46**:794–801.

30. Naruishi K, Yumoto H, Kido J. Clinical effects of low body mass index on geriatric status

in elderly patients. *Exp Gerontol* 2018;**110**:86–91.

Table 1.

Descriptive measures of numerical predictors according to death by the neoplasms, diseases of respiratory system (DRS), diseases of circulatory system (DCS), and by the other specific causes, n=1,767.

Measure		Death by neoplasms		Death by DRS		Death by DCS		Death by other causes		Total sample
		No	Yes	No	Yes	No	Yes	No	Yes	
Age	count	1708.0	59.0	1709.0	58.0	1663.0	104.0	1369.0	398.0	1767.0
	mean	71.5	75.2	71.2	84.7	71.1	79.6	73.5	65.1	71.6
	Std	9.5	10.3	9.3	8.7	9.3	9.8	9.2	7.8	9.6
	Min	60.0	60.0	60.0	61.0	60.0	60.0	60.0	60.0	60.0
	25%	63.0	65.5	63.0	80.3	63.0	73.0	66.0	61.0	63.0
	50%	69.0	76.0	69.0	85.0	69.0	81.0	73.5	63.0	69.0
	75%	79.0	82.5	79.0	90.8	79.0	87.0	81.0	64.0	79.0
	max	103.0	95.0	103.0	102.0	103.0	100.0	102.0	103.0	103.0
	p-value*		0.009		0.000		0.000		0.000	-
Daily sitting time	count	1598.0	57.0	1601.0	54.0	1556.0	99.0	1301.0	354.0	1655.0
	mean	4.5	5.6	4.5	6.0	4.4	6.1	4.5	4.6	4.5
	std	2.8	3.2	2.8	2.8	2.7	3.8	2.8	3.0	2.8
	min	0.0	1.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0
	25%	2.4	3.0	2.3	3.8	2.3	3.3	2.4	2.6	2.4
	50%	4.0	5.0	4.0	6.0	3.9	5.0	3.9	4.0	4.0
	75%	6.0	8.0	6.0	8.0	6.0	8.1	6.0	6.0	6.0
	max	24.0	12.0	24.0	12.0	24.0	24.0	24.0	24.0	24.0
	p-value*		0.010		0.011		0.002		0.389	-
Body mass index	count	1679.0	59.0	1680.0	58.0	1635.0	103.0	1344.0	371.0	1738.0
	mean	25.9	24.8	26.1	20.7	26.1	22.8	25.9	27.5	25.9
	std	6.8	7.0	6.7	8.1	6.7	8.3	6.1	6.3	6.8
	min	0.0	10.0	0.0	0.0	0.0	0.0	0.4	0.5	0.0
	25%	23.0	21.3	23.0	18.7	23.1	19.8	22.8	24.4	22.9

	50%	26.2	24.7	26.3	22.6	26.2	23.7	25.8	27.5	26.1
	75%	29.6	28.6	29.7	24.7	29.7	27.4	29.2	31.1	29.6
	max	53.6	41.1	53.6	41.3	53.6	42.2	53.6	53.6	53.6
	p-value*		0.112		0.000		0.021		0.000	-
Grip strength	count	1639.0	56.0	1642.0	53.0	1601.0	94.0	1359.0	367.0	1695.0
	mean	24.2	27.6	24.2	28.5	24.4	23.0	23.7	26.4	24.3
	std	13.4	19.2	13.0	26.6	13.2	19.6	13.7	12.9	13.6
	min	1.5	6.5	1.5	2.0	1.5	2.0	1.5	4.5	1.5
	25%	16.0	18.3	16.5	13.0	16.5	13.5	15.5	19.0	16.3
	50%	22.0	23.9	22.0	20.0	22.0	18.8	21.0	24.5	22.0
	75%	29.5	31.5	29.5	30.5	29.8	25.0	29.0	31.1	29.5
	max	98.0	97.0	98.0	97.0	98.0	97.0	98.0	97.0	98.0
	p-value*		0.334		0.390		0.001		0.000	-

*P-value corresponding to the Wilcoxon test.

Table 2.

Performance metrics for the best algorithms of each outcome class for the test set.

Algorithm	Classes	AUC[IC95%]	Default		Optimal threshold*		Accuracy of the 25% k-tops
			Sensitivity	Specificity	Sensitivity	Specificity	
LGBM	Death by DRS	0.89[0.85-0.93]	0.12	0.98	0.88	0.77	0.71
	Death by DCS	0.67[0.60-0.73]	0.10	0.96	0.68	0.57	0.68
	Death by neoplasms	0.52[0.41-0.64]	0.00	1.00	0.33	0.79	0.11
	Death by the other specific causes	0.87[0.84-0.90]	0.73	0.85	0.86	0.78	1.00
XGB	Death by DRS	0.87[0.82-0.92]	0.12	0.97	0.94	0.75	1.00
	Death by DCS	0.63[0.55-0.71]	0.10	0.96	0.65	0.62	0.77
	Death by neoplasms	0.57[0.46-0.69]	0.00	1.00	0.50	0.64	0.11
	Death by the other specific causes	0.87[0.84-0.90]	0.72	0.89	0.82	0.82	1.00

*For LGBM, the optimal threshold for death by DRS=0.000085, DCS=0.001764, neoplasms=0.001766, and for the other causes=0.688063. For XGB, the optimal threshold for death by DRS=0.000764, DCS=0.001849, neoplasms=0.001310, and for the other causes=0.183196.

Figure 1: ROC curve for the test set of LGBM (a) and XGB (b) for death by DRS, DCS, neoplasm and other specific causes.

Figure 2: Shapley values plots of feature importance for death by DRS (a), DCS (b), neoplasms (c) and other causes (d).

Supplement

Supplementary Table S1: Results for the algorithms on the train set.

Model	Accuracy	Recall	Prec.	F1	Kappa
Extra Trees Classifier	0.978600	0.978600	0.979000	0.978500	0.973200
Light Gradient Boosting Machine	0.963400	0.963400	0.966100	0.962700	0.954200
Random Forest Classifier	0.960400	0.960400	0.964000	0.959600	0.950500
Extreme Gradient Boosting	0.958700	0.958700	0.961200	0.957600	0.948300
CatBoost Classifier	0.956400	0.956400	0.960000	0.955600	0.945500
Decision Tree Classifier	0.910600	0.910600	0.920500	0.902600	0.888200
Gradient Boosting Classifier	0.899900	0.899900	0.901700	0.894000	0.874800
K Neighbors Classifier	0.863500	0.863500	0.864600	0.849800	0.829400
Quadratic Discriminant Analysis	0.767900	0.767900	0.791300	0.734400	0.709800
Ada Boost Classifier	0.712600	0.712600	0.709700	0.706100	0.640700
Logistic Regression	0.612000	0.611900	0.606100	0.598900	0.514900
Linear Discriminant Analysis	0.576100	0.576100	0.569900	0.564700	0.470100
Ridge Classifier	0.569600	0.569600	0.570100	0.550000	0.462000
SVM - Linear Kernel	0.544200	0.543900	0.570900	0.521800	0.430100
Naive Bayes	0.326300	0.326300	0.465100	0.266500	0.157800

Supplementary Table S2: Absolute and relative frequencies of predictors according to the outcomes: Health, well-being and Aging (SABE) Study, n=1,767.

Predictors	Factors	Total		Death by DRS					Death by DCS					Death by neoplasm					Death by other causes				
		n	%	No	%	Yes	%	p-value ^a	No	%	Yes	%	p-value ^a	No	%	Yes	%	p-value ^a	No	%	Yes	%	p-value ^a
Total		-	-	1709	96.7	58	3.3	-	1663	94.1	104	5.9	-	1708	96.7	59	3.3	-	1369	77.5	398	22.5	-
Gender	female	1096	62.0	1073	97.9	23	2.1	0.001	1035	94.4	61	5.6	0.531	1071	97.7	25	2.3	0.002	1511	76.6	256	23.4	0.311
Years of schooling	4-7 years	659	37.3	644	97.7	15	2.3	0.004	616	93.5	43	6.5	0.014	633	96.1	26	3.9	0.448	505	76.6	154	23.4	<0.001
	1-3 years	452	25.6	435	96.2	17	3.8		428	94.7	24	5.3		442	97.8	10	2.2		372	82.3	80	17.7	
	8 years and more	365	20.7	357	97.8	8	2.2		353	96.7	12	3.3		353	96.7	12	3.3		234	64.1	131	35.9	
	no schooling	270	15.3	252	93.3	18	6.7		245	90.7	25	9.3		260	96.3	10	3.7		253	93.7	17	6.3	
Income is enough	no	898	50.8	876	97.6	22	2.4	0.057	848	94.4	50	5.6	0.001	868	96.7	30	3.3	0.485	704	78.4	194	21.6	0.418
	yes	829	46.9	799	96.4	30	3.6		783	94.5	46	5.5		800	96.5	29	3.5		632	76.2	197	23.8	
	no response	40	2.3	34	85.0	6	15.0		32	80.0	8	20.0		40	100.0	0	0.0		33	82.5	7	17.5	
Live alone	yes	264	14.9	257	97.3	7	2.7	0.663	245	92.8	19	7.2	0.401	256	97.0	8	3.0	0.907	214	81.1	50	18.9	0.152
Race/Skin color	white	1090	61.7	1045	95.9	45	4.1	0.040	1018	93.4	72	6.6	0.221	1048	96.1	42	3.9	0.126	897	82.3	193	17.7	<0.001
	black or mixed	539	30.5	529	98.1	10	1.9		515	95.5	24	4.5		528	98.0	11	2.0		351	65.1	188	34.9	
	other	138	7.8	135	97.8	3	2.2		130	94.2	8	5.8		132	95.7	6	4.3		121	87.7	17	12.3	
Self-rated health	regular	798	45.2	775	97.1	23	2.9	0.014	746	93.5	52	6.5	0.101	769	96.4	29	3.6	0.003	632	79.2	166	20.8	0.061
	excellent/good	790	44.7	770	97.5	20	2.5		754	95.4	36	4.6		772	97.7	18	2.3		592	74.9	198	25.1	
	bad/very bad	160	9.1	149	93.1	11	6.9		147	91.9	13	8.1		148	92.5	12	7.5		130	81.3	30	18.8	
Smoking	never	919	52.0	898	97.7	21	2.3	0.027	863	93.9	56	6.1	0.156	893	97.2	26	2.8	0.452	738	80.3	181	19.7	0.005
	stopped	630	35.7	600	95.2	30	4.8		600	95.2	30	4.8		605	96.0	25	4.0		476	75.6	154	24.4	
	smoking currently	218	12.3	211	96.8	7	3.2		200	91.7	18	8.3		210	96.3	8	3.7		155	71.1	63	28.9	
Alcohol consumption	never	1289	72.9	1242	96.4	47	3.6	0.38	1205	93.5	84	6.5	0.043	1247	96.7	42	3.3	0.155	1004	77.9	285	22.1	0.618
	until 1 day/week	270	15.3	264	97.8	6	2.2		263	97.4	7	2.6		264	97.8	6	2.2		203	75.2	67	24.8	

	2 days or more	204	11.5	199	97.5	5	2.5		191	93.6	13	6.4		193	94.6	11	5.4		159	77.9	45	22.1	
Cognitive impairment	yes	270	15.3	239	88.5	31	11.5	<0.001	230	85.2	40	14.8	<0.001	256	94.8	14	5.2	0.099	229	84.8	41	15.2	0.002
Diabetes mellitus	yes	383	21.7	369	96.3	14	3.7	0.764	350	91.4	33	8.6	0.015	367	95.8	16	4.2	0.384	289	75.5	94	24.5	0.318
Respiratory diseases	yes	188	10.6	170	90.4	18	9.6	0.001	169	89.9	19	10.1	0.015	179	95.2	9	4.8	0.34	159	84.6	29	15.4	0.018
Cardiovascular diseases	yes	402	22.8	380	94.5	22	5.5	0.008	364	90.5	38	9.5	0.001	378	94.0	24	6.0	0.001	337	83.8	65	16.2	0.001
Cerebrovascular diseases	yes	148	8.4	140	94.6	8	5.4	0.203	125	84.5	23	15.5	<0.001	139	93.9	9	6.1	0.089	127	85.8	21	14.2	0.015
Hypertension	yes	1109	62.8	1071	96.6	38	3.4	0.762	1040	93.8	69	6.2	0.500	1073	96.8	36	3.2	0.885	884	79.7	225	20.3	0.004
Arthrosis or other joint disease	yes	596	33.7	575	96.5	21	3.5	0.791	561	94.1	35	5.9	1.000	580	97.3	16	2.7	0.341	481	80.7	115	19.3	0.024
Mental disorders	yes	425	24.1	410	96.5	15	3.5	0.864	399	93.9	26	6.1	0.909	410	96.5	15	3.5	0.924	322	75.8	103	24.2	0.367
Have any fall last year	yes	547	31.0	519	94.9	28	5.1	0.006	513	93.8	34	6.2	0.775	530	96.9	17	3.1	0.827	427	78.1	120	21.9	0.739
Unable to perform the physical tests	yes	157	8.9	141	89.8	16	10.2	0.001	127	80.9	30	19.1	<0.001	151	96.2	6	3.8	0.905	133	84.7	24	15.3	0.030
Maintain their feet in side by side ^b	≥ 10s	1540	87.2	1503	97.6	37	2.4	<0.001	1470	95.5	70	4.5	<0.001	1490	96.8	50	3.2	0.716	1192	77.4	348	22.6	0.915
	unable	227	12.8	206	90.7	21	9.3		193	85.0	34	15.0		218	96.0	9	4.0		177	78.0	50	22.0	
Heel of one foot alongside the big toe of the other foot ^b	≥ 10s	1503	85.1	1468	97.7	35	2.3	<0.001	1437	95.6	66	4.4	<0.001	1456	96.9	47	3.1	0.319	1158	77.0	345	23.0	0.341
	unable	264	14.9	241	91.3	23	8.7		226	85.6	38	14.4		252	95.5	12	4.5		211	79.9	53	20.1	
Heel of one foot directly in front of the other foot ^b	≥ 10s	1273	72.0	1251	98.3	22	1.7	<0.001	1225	96.2	48	3.8	<0.001	1236	97.1	37	2.9	0.254	950	74.6	323	25.4	<0.001
	unable	296	16.8	269	90.9	27	9.1		256	86.5	40	13.5		281	94.9	15	5.1		238	80.4	58	19.6	
	3-9s	146	8.3	140	95.9	6	4.1		137	93.8	9	6.2		140	95.9	6	4.1		131	89.7	15	10.3	
	less than 3s	52	2.9	49	94.2	3	5.8		45	86.5	7	13.5		51	98.1	1	1.9		50	96.2	2	3.85	

Walking time ^b	less than 3.62s	515	29.1	512	99.4	3	0.6	<0.001	502	97.5	13	2.5	<0.001	502	97.5	13	2.5	0.491	344	66.8	171	33.2	<0.001
	3.62-4.65s	478	27.1	467	97.7	11	2.3		457	95.6	21	4.4		464	97.1	14	2.9		356	74.5	122	25.5	
	4.66-6.52s	374	21.2	362	96.8	12	3.2		355	94.9	19	5.1		359	96.0	15	4.0		333	89.0	41	11.0	
	unable	265	15.0	244	92.1	21	7.9		226	85.3	39	14.7		255	96.2	10	3.8		217	81.9	48	18.1	
	> 6.52s	135	7.6	124	91.9	11	8.1		123	91.1	12	8.9		128	94.8	7	5.2		119	88.1	16	11.9	
Feel safe to stand up and sit down five times with arms folded across their chests ^b																							
yes		1440	81.5	1408	97.8	32	2.2	<0.001	1382	96.0	58	4.0	<0.001	1393	96.7	47	3.3	0.843	1101	76.5	339	23.5	0.038
Stand up and sit down five times as quickly as possible ^b	≥ 16.7s	547	31.0	528	96.5	19	3.5	<0.001	516	94.3	31	5.7	<0.001	523	95.6	24	4.4	0.201	459	83.9	88	16.1	<0.001
	13.7-16.69s	381	21.6	379	99.5	2	0.5		368	96.6	13	3.4		370	97.1	11	2.9		291	76.4	90	23.6	
	unable	377	21.3	345	91.5	32	8.5		328	87.0	49	13.0		362	96.0	15	4.0		318	84.4	59	15.6	
	less than 11.19s	232	13.1	230	99.1	2	0.9		224	96.6	8	3.4		229	98.7	3	1.3		146	62.9	86	37.1	
	11.2-13.69s	230	13.0	227	98.7	3	1.3		227	98.7	3	1.3		224	97.4	6	2.6		155	67.4	75	32.6	

Notes: DRS= Diseases of the respiratory system; DCS= Diseases of the circulatory system; ^ap-values corresponding to the qui-square test. ^bTopics of the Short Physical Performance Battery (SPPB).

Supplementary Table S3: Hyperparameters for the light gradient boosted machine (LGBM) model.

Parameters	
estimator__boosting_type	gbdt
estimator__class_weight	None
estimator__colsample_bytree	1
estimator__importance_type	split
estimator__learning_rate	0.1
estimator__max_depth	-1
estimator__min_child_samples	20
estimator__min_child_weight	0.001
estimator__min_split_gain	0
estimator__n_estimators	100
estimator__n_jobs	-1
estimator__num_leaves	31
estimator__objective	None
estimator__random_state	42
estimator__reg_alpha	0
estimator__reg_lambda	0
estimator__silent	True
estimator__subsample	1
estimator__subsample_for_bin	200000
estimator__subsample_freq	0
estimator	LGBMClassifier(random_state=42)

Supplementary Table S4: Hyperparameters for the extreme gradient boosted (XGB) model.

Parameters	
estimator__objective	binary:logistic
estimator__base_score	None
estimator__booster	None
estimator__colsample_bylevel	None
estimator__colsample_bynode	None
estimator__colsample_bytree	None
estimator__gamma	None
estimator__gpu_id	None
estimator__importance_type	gain
estimator__interaction_constraints	None
estimator__learning_rate	None
estimator__max_delta_step	None
estimator__max_depth	None
estimator__min_child_weight	None
estimator__missing	NaN
estimator__monotone_constraints	None
estimator__n_estimators	100
estimator__n_jobs	-1
estimator__num_parallel_tree	None
estimator__random_state	42
estimator__reg_alpha	None
estimator__reg_lambda	None
estimator__scale_pos_weight	None
estimator__subsample	None
estimator__tree_method	None
estimator__validate_parameters	None
estimator__verbosity	0
estimator	XGBClassifier(base_score=None, booster=None, c...
n_jobs	None

Supplementary Figure S1: Representation of the sample design of SABE Study, and the data used in this present analysis.

Supplementary Figure S2: ROC curve for the test set of Extra trees classifier (a), random forest classifier (b), and catboost (c), for death by DRS, DCS, neoplasm and other specific causes.

Supplementary Figure S3: ROC curve for the test set of LGBM for death by DRS, DCS, neoplasm and other specific causes, with the SMOTE method of resampling.

4.4ARTIGO 4

Early identification of older individuals at risk of mobility decline with machine learning

Authors: Carla Ferreira do Nascimento, MSc^{1*} (carlafn@usp.br); André Filipe de Moraes Batista, PhD¹ (andrefmb@usp.br); Yeda Aparecida Oliveira Duarte, PhD² (yedaenf@usp.br); Alexandre Dias Porto Chiavegatto Filho, PhD¹ (alexdiasporto@usp.br).

¹ School of Public Health, University of São Paulo, São Paulo, Brazil

² School of Nursing, University of São Paulo, São Paulo, Brazil

*** Corresponding author:**

Carla Ferreira do Nascimento, Department of Epidemiology, School of Public Health, University of São Paulo, Avenida Doutor Arnaldo, 715, 1º andar, CEP: 01246-904, Telephone number: 55 (11)3061-7737. E-mail: carlafn@usp.br

Funding

This work was supported by the Brazilian National Research Council (CNPq), grant number 152494/2016-2.

Conflicts of Interest

None.

Early identification of older individuals at risk of mobility decline with machine learning

Abstract

Background: The early identification of individuals at risk of mobility decline can improve targeted strategies of prevention. We aimed to evaluate the predictive performance of machine learning (ML) algorithms in identifying older individuals at risk of future mobility decline.

Methods: We used data from the SABE Study (Health, Well-being and Aging Study), a representative sample of people aged 60 years and more, living in the Municipality of São Paulo, Brazil. Mobility decline was assessed 5 years after admission in the study by self-reported difficulty to walk a block, climb steps, being able to stoop, crouch and kneel, or lifting or carrying weights greater than 5 kg. Popular machine learning algorithms were trained in 70% of the sample with 10-fold cross-validation, and predictive performance metrics were obtained from applying the trained algorithms to the other 30% (test set).

Results: Of the 1,615 individuals, 48% developed difficulty in at least one of the four tasks, 32% in stooping, crouching and kneeling, and 30% in carrying weights. The random forest algorithm had the best predictive performance for most outcomes. The tasks that the algorithm was able to predict with better performance were crouching and kneeling (AUC-ROC: 0.81[0.76-0.85]), and lifting or carrying weights (AUC-ROC: 0.80[0.75-0.84]). Age was the most important variable for the algorithms, followed by education and back pain, according to the SHAP (SHapley Additive exPlanations) values.

Conclusion: Applications of ML algorithms are a promising tool to identify older patients at risk of mobility decline, with the potential of improving targeted preventive programs.

Keywords: Prediction modeling, disability, functional limitation, decision support tool.

Introduction

The aging process increases the likelihood of developing mobility limitations, which can arise from the physiological aging of body systems and the presence of chronic diseases, which are directly affected from lifestyle and environmental characteristics (Brach et al., 2017; Rantakokko et al., 2013). Functional mobility comprises several functions that include changing body position, carrying, moving or manipulating objects, walking, running, climbing, and even using transportation (Centro Colaborador da Organização Mundial da Saúde para a Família da Classificações Internacionais em Português, 2015). To capture these different aspects of mobility, some self-reported measures have been proposed in the literature to evaluate the impact of mobility limitation in older population, such as walking, climbing stairs, carrying weights, and stooping, crouching or kneeling (Bendayan et al., 2016; Cornman et al., 2021; Guralnik & Ferrucci, 2003; Nagi, 1976).

The early identification of individuals at risk of mobility decline could help to allocate them in targeted strategies of prevention. Some tests (Guralnik et al., 1994), scales, and simple algorithms (Gomez et al., 2017) have been used to classify older adults in different categories of functional capacity (Guralnik & Ferrucci, 2003), and to identify the risk of adverse events, such as falls and death (Buckinx et al., 2018). Physical performance measures, such as grip strength, gait speed and balance tests have been widely used to predict mobility disability in older adults (Cavanaugh et al., 2018; Deshpande et al., 2013). Other authors have also developed models to predict future mobility decline, such as Hicks et al, 2012, that used regression trees to predict inability to walk 1km or climbing stairs (Hicks et al., 2012).

More recently, machine learning algorithms have been increasingly used to predict adverse health outcomes, frequently with better overall performance than more parsimonious techniques (Odden & Melzer, 2019; Rajkomar et al., 2019; Rose, 2013; Speiser et al., 2020) ,

such as Kheirkhahan et al, 2016, that used machine learning to predict walking speed decline (Kheirkhahan et al., 2016). However, they used accelerometry data, which makes it difficult to apply these models comprehensively in the community. To the best of our knowledge, there are no studies that used machine learning to predict mobility decline in a representative sample of community-dwelling older adults.

This study aims to evaluate the predictive performance of machine learning algorithms in identifying older individuals at risk of developing mobility decline within five years, by using a representative sample of older residents from the Municipality of São Paulo, Brazil.

Methods

We analyzed data from SABE (Health, Well-being and Aging Study), for which detailed methods were published elsewhere (Lebrão et al., 2018). The sample is representative of community-dwelling individuals aged 60 years and more, living in the Municipality of São Paulo, Brazil. Briefly, clustered sampling was performed from 72 census tracts, and the participants were selected by probability proportional to size approach. The study has a longitudinal design and is characterized by multiple cohorts, collected in the following years: 2000, 2006, 2010, and 2015. In each subsequent wave, the previous cohorts were revisited and a new probabilistic cohort, composed of 60-64 years-old individuals, was added to the sample.

For the present analysis, the subjects admitted in the study in 2000, 2006, and 2010, and that were revisited in the subsequent wave, were included (totaling 1,615 individuals). All participants signed a statement of informed consent, and individual anonymity was preserved. The research project received approval from the Human Research Ethics Committee of the School of Public Health/University of São Paulo (Protocol number: 315/99, 1345, 2044, and 3.600.782).

The predictors were obtained during the admission interview and the outcomes on the following wave (around five years later). Although this time of follow-up could be considered long for certain outcomes, mobility decline is progressive in most older people, frequently occurring throughout 2 years or longer (Guralnik et al., 2001). Mobility decline was evaluated by the self-reported difficulty according to the following questions: “Do you have any difficulty walking a street (block)?”, “Do you have any difficulty walking up the stairs without resting?”, “Do you have any difficulty in bending, kneeling, or crouching?”, “Do you have any difficulty in lifting or carrying weights over 5 kg, like a heavy shopping bag?”. The predictions were performed for the composite outcome, i.e., limitation in any of the four tasks, and for each task separately. From the total of 1,615 individuals, the ones who presented the correspondent limitation in baseline for each of the outcomes were excluded from the analysis. For example, individuals with limitations in climbing steps in admission were excluded from the analysis to predict limitation in climbing steps. This procedure generated different samples for each outcome as observed in Table 1.

The predictors were the following health, socioeconomic and demographic characteristics available from the questionnaire: age in years, body mass index (BMI), gender, race/skin color (white, mixed, black or other), education (up to 3 years, 4-7 years, 8 or more years), report of falls last year (none, one, 2 or more), income sufficiency (yes/no), living alone (yes/no), smoking (current smokers, former smokers and never smokers), alcohol consumption per week (less than 1 day, 1-3 days, 4 or more days), presence of each non-communicable diseases (hypertension, diabetes mellitus, pulmonary disease, heart disease, stroke, arthrosis or arthritis and osteoporosis), presence of chest pain, back pain, edema, and severe fatigue or tiredness in the last 12 months, used antidepressants in the last 12 months, the 15 items of Geriatrics Depression Scale (GDS) (Paradela et al., 2005), and cognitive deficit (characterized by a score of 12 or less in modified version of the Mini Mental State Exam (Icaza & Albala,

1999)). The complete list of the 38 predictors and the description of the sample according to the outcomes are presented in Supplementary Table 1 and 2.

After obtaining the descriptive metrics, we randomly separated the dataset into training (70%) and test (30%). Then, the numeric features were standardized by the z-score, and the missing values were imputed by the mean. In the case of categorical features, missing values were imputed by the mode. These parameters were obtained from the training set and then applied to the test set in order to avoid information leakage. We oversampled the training set by randomly duplicating the minority class (using the random-over method).

We trained 15 popular algorithms (gradient boosting trees, XGBoost, catboost, lightGBM, linear discriminant analysis, logistic regression, Ridge logistic regression, AdaBoost classifier, extra trees classifier, random forest, naive Bayes, support vector machines, quadratic discriminant analysis, k-neighbors classifier and classification tree) with 10-fold cross-validation for hyperparameter tuning using hyperopt Bayesian optimization. The hyperparameters and the overall predictive performance were always evaluated by the area under the ROC curve (AUC-ROC). The list of algorithms and the performance metrics for each outcome in the training set are shown in Supplementary Table 3. The hyperparameters are presented in Supplementary Table 4.

The final models were applied to the test set, where the performance metrics (AUC-ROC, sensitivity and specificity) were obtained. These metrics are presented in Supplementary Table 5. Optimal thresholds were calculated to optimize the balance between sensitivity and specificity, identifying the threshold with the largest geometric mean (square root (sensitivity * specificity)) (Fernández et al., 2018). The contribution of each variable to the models was accessed by the SHAP (SHapley Additive exPlanations) values (Lundberg & Lee, 2017), a method based on coalitional game theory that can be interpreted as the average contribution of

a feature to a specific prediction compared to the average prediction of the dataset. With the SHAP values, it is possible to observe feature importance and its effects (Lundberg & Lee, 2017). All analyses were performed in Python. For training the machine learning algorithms we used a customized version of PyCaret (PyCaret.org, 2020) (LABDAPS MLFlow (Machine Learning Workflow by Big Data and Predictive Analytics in Healthcare Lab - University of São Paulo [LABDAPS-USP])). The complete code of the analyses is available in <https://github.com/carlafn/Mobility_decline_prediction>.

Results

The most prevalent outcome was limitation in stooping, crouching, and kneeling. Of the 930 individuals without this limitation in baseline, 31.7% presented it in the follow-up. The incidence was the lowest for limitation in walking (19.1%). Of the 720 subjects without any of the outcomes in baseline, 48.2% presented difficulty in at least one of the outcomes in the follow-up (Table 1).

Individual characteristics varied according to the predicted outcome. Female gender was the most prevalent for all the four specific sub-samples, ranging between 54.8 to 62.8%. However, considering mobility decline as a composite outcome, women represented 49.2% of all included individuals. Regarding age, we also observed discrete variations according to the outcome analyzed, with its mean ranging from 67.12 to 68.16. The characterization and the distribution of the sample are presented in Supplementary Table 1 and 2.

The outcomes with the best predictive performance were stooping, crouching and kneeling, followed by lifting or carrying weights, with AUC-ROCs of 0.81 and 0.80, respectively (Figure 1). The optimal threshold for these predictions identified 79% and 80% of all individuals who experienced the respective outcomes, with a specificity of 77% and 70%.

The composite outcome, i.e., wherein the individuals presented a limitation in any of the four mobility tasks, had the worst overall prediction, with an AUC-ROC of 0.75. The performance metrics for the best algorithms in the test set are shown in Table 2. The calibration of the algorithms for each of the tasks is presented in Supplementary Figure 1.

Figure 2 shows the variables that most contributed to the predictions, according to the SHAP values from the test set. Age was the most important variable for all the five outcomes, and education was in the top-5 for all outcomes. The presence or not of back pain in the last 12 months appeared within the five most important predictors for crouching and kneeling, carrying weights, and climbing stairs. Supplementary Figure 2 presents the SHAP summary plots, with the impact of each variable for the model output. In these plots the y-axis indicates each feature in order of importance, the x-axis the SHAP value, and the gradient color indicates the original value of variables (higher values are red, and lower values, blue), with each point representing an observation. Thus, we can observe in the five plots of Supplementary Figure 2, for example, that higher values of age are associated to positive outcomes. The male gender, on the other hand, had a negative impact on the first 4 outcomes (Supplementary Figure 2 (a), (b), (c) and (d)).

Discussion

According to our study, machine learning algorithms presented a high ability to predict future mobility decline for each of the four separate outcomes analyzed, with an AUC-ROC ranging from the 0.78 to 0.81 on the test set (unseen data). For the composite mobility outcome, however, performance was lower, with AUC-ROC of 0.75, indicating that performing separate predictions for each task leads to improved results.

There is evidence that mobility decline follows a temporal hierarchy, as the ability to perform tasks such as stooping tends to diminish earlier than others such as walking (Bendayan et al., 2016). Although some features are common to all mobility impairments, previous studies show that some specific tasks have different associated factors (Cornman et al., 2021). Furthermore, individuals with accumulated impairments have, on average, different characteristics than the less impaired (Cornman et al., 2021). According to our analysis, there was a tendency for better prediction performance for more complex tasks, which could indicate that the predictors are more related to the initial process of declining mobility than the later stage. This also could explain why the algorithms had a lower predictive performance for mobility decline as a composite outcome. For this outcome, the sensitivity was 0.60, which means that 40% of positive cases would not be identified using the optimal threshold.

The set of predictors available from this study were better able to identify individuals who will present difficulties in stooping, crouching and kneeling, according to the AUC-ROC (0.81). This task is essential to the execution of many daily life activities such as picking up an object on the floor, and its limitation is associated with a weakness of the lower limb muscles, balance impairment, and joint limitations (Hernandez et al., 2010; Seidel et al., 2011). Even without using physical measures and performance tests, the random forest algorithm was able to identify 79% of the individuals who presented impairment in these activities after five years, with a specificity of 77%.

The ability to lift weights higher than 5kg is important for independence in carrying bags of groceries during shopping, for example. A study conducted in 6,841 European older adults showed that difficulty in this task was associated with an average increase of 80% in the risk of having a disability in instrumental activities of daily living (IADL), like cooking, shopping, and housework (Seidel et al., 2011). In our study, the random forest algorithm

identified 80% of individuals who presented future limitations in carrying weights, with a specificity of 70%.

In addition to being an important skill for locomotion and accessibility, the habit of climbing stairs increases physical activity (Jennings et al., 2017), and its impairment may discourage older persons from walking outdoors (Edwards & Dulai, 2018). Thus, identifying individuals who will have a decline in this ability could promote early interventions in order to help prevent further limitations. In our study, 73% of all individuals who lost this ability in 5 years were identified at baseline. Among those who were classified by the algorithm as not developing a future limitation in climbing stairs, 74% did not in fact have this difficulty in the follow up. Hicks et al, 2012, using muscle strength and power tests applied regression trees to predict future difficulty in walking or climbing stairs (Hicks et al., 2012). The C-index obtained by the authors were 71% for men, and 68,7% for women (Hicks et al., 2012). Our algorithms achieved an AUC-ROC of 79% for climbing stairs, and 78% for difficulty in walking.

Lastly, walking ability is one of the most studied aspects of mobility and is directly associated with mortality risk and independence in outdoor activities (Duim et al., 2017; Liu et al., 2016). Studies that have applied machine learning to predict this skill have so far used laboratory-based measures (Hu et al., 2018; Kheirkhahan et al., 2016). A study conducted by Kheirkhahan et al, 2016, tested the performance of machine learning algorithms in predicting the ability of older individuals to walk a distance of 400 meters, and the better algorithm had a sensitivity of 74%, and specificity of 83% (Kheirkhahan et al., 2016). In our study, difficulty in walking had the lowest AUC-ROC (0.78), compared to the other mobility tasks, with 67% of sensitivity and 81% of specificity. However, differently from the study of Kheirkhahan et al, 2016, we did not use data from electronic devices, and most of our predictors were self-reported, based on a simple and straightforward questionnaire.

Regarding variable importance, age was the one that most contributed to the predictions, which is expected since mobility decline has a well-established association with aging (Stringhini et al., 2018). Education also appeared in the top-5 lists of the four outcomes, indicating that it is an important feature for mobility decline prediction. Education level is considered a proxy for socioeconomic status, and is frequently mentioned in the literature as a consistent risk factor for poor health and mobility impairment (Latham, 2014; Stringhini et al., 2018). The interpretation of SHAP values should be made with caution. It presents the variables that most influenced the decision-making process of the machine learning algorithms, not the direct relationship between the variables, and should not be used to perform statistical inference.

Excluding age, presence of back pain was the feature that most contributed for the prediction of stooping, kneeling and crouching, and was also part of the top-5 for the prediction of limitations for climbing stairs and for carrying weights. This disabling symptom is common in the older population, and recent publications found that low back pain is the main reason for a premature exit from the workforce, and one of the most important causes of the need for rehabilitation services worldwide (Cieza et al., 2020; Hartvigsen et al., 2018).

Although the development of SHAP values has brought an important advance in the interpretability of machine learning models, more parsimonious algorithms with easily interpretable coefficients may be of interest to researchers. Thus, in some cases a simple model, such as the logistic regression, could be an acceptable choice. When comparing the AUC-ROC, there were not large differences between the best algorithms and logistic regression (Supplementary Table 5). However, in a prediction context, even small differences could bring significant cumulative improvements to individuals and important reductions in healthcare costs. According to our results, the performance of the best algorithms in relation to LR was higher for the limitation in crouching and kneeling. In this case, logistic regression would leave out about 6 individuals who presented the outcome compared to the random forest algorithm,

based on the sensitivity for the 50% threshold in the test set. Lastly, although logistic regression is the simpler algorithm, all models are reasonably similar to run with current programming libraries.

One of the limitations in the use of machine learning in clinical practice has been the difficulty in applying the models in situations where there is no access to computational resources. However, many advances have taken place in recent years and these barriers have been greatly reduced (Loh, 2018). For example, it is currently possible to get risk scores calculated by machine learning algorithms using mobile apps (Shung et al., 2020). With the advancement in access to these tools, the choice of the most appropriate model to assist in health decision-making will be increasingly based on predictive performance. Algorithms will perform differently depending on the data set and the outcome analyzed, therefore several algorithms should be continuously tested to evaluate the one that best fits the specific problem (Santos et al., 2020).

To our knowledge, there are no studies with a similar approach in the literature. Previous studies that used machine learning to predict health outcomes in older adults mostly focused on mortality (do Nascimento et al., 2021; Santos et al., 2019; Wallace et al., 2019), falls (Speiser et al., 2020; Ye et al., 2020), and gait (Hu et al., 2018; Kheirkhahan et al., 2016). It is worth mentioning that most studies of prediction of falls and ability to walk have used laboratory measures (Hu et al., 2018; Kheirkhahan et al., 2016; Ye et al., 2020), performance tests (Hu et al., 2018; Speiser et al., 2020), or vital signs (Speiser et al., 2020). Despite the logistical challenges of a home-based study, the predictors included in our analysis are questionnaire-based and easier to be collected in the community. While on the one hand, it may hinder the predictive ability of the models, on the other hand, our results are especially promising regarding its practical application in poorer areas and in developing countries.

Some limitations need to be mentioned. First, during the period in which the data were collected, important contextual changes have occurred, which may have introduced some variability to the data. In order to minimize this, we selected only variables present in all waves of the study. Second, our results are not generalizable until external validations are conducted. Despite this limitation, in addition to using cross-validation techniques to adjust the models, we tested our algorithms on a sample that was not used in the tuning of hyperparameters, in order to decrease the effect of overfitting to the training sample.

Mobility decline is considered an important risk factor for adverse health outcomes, such as mortality and limitations in activities of daily living (Musich et al., 2018; Olaya et al., 2018; Seidel et al., 2011), and a growing public health challenge in the current context of population aging.(35) The present study showed that the application of machine learning algorithms can be helpful in the identification of older individuals at risk of developing a decline in specific functional activities. Future trials should be performed to test the practical applications of machine learning algorithms in screening and the assignment of individuals to targeted preventive strategies, in order to improve patient outcomes and the efficient allocation of healthcare resources.

References

- Bendayan, R., Cooper, R., Wloch, E. G., Hofer, S. M., Piccinin, A. M., & Muniz-Terrera, G. (2016). Hierarchy and Speed of Loss in Physical Functioning: A Comparison Across Older U.S. and English Men and Women. *The Journals of Gerontology Series A: Biological Sciences and Medical Sciences*, 72(8), glw209. <https://doi.org/10.1093/gerona/glw209>

Brach, J., Rosano, C., & Studenski, S. (2017). Mobility. In K. G. Edmonson & K. J. Davis. (Eds.), *Hazzard's Geriatric Medicine and Gerontology* (7th ed., pp. 2132–2147).

McGraw-Hill Education.

Buckinx, F., Croisier, J. L., Reginster, J. Y., Lenaerts, C., Brunois, T., Rygaert, X.,

Petermans, J., & Bruyère, O. (2018). Prediction of the Incidence of Falls and Deaths

Among Elderly Nursing Home Residents: The SENIOR Study. *Journal of the American Medical Directors Association*, 19(1), 18–24.

<https://doi.org/10.1016/j.jamda.2017.06.014>

Cavanaugh, E. J., Richardson, J., McCallum, C. A., & Wilhelm, M. (2018). The Predictive

Validity of Physical Performance Measures in Determining Markers of Preclinical

Disability in Community-Dwelling Middle-Aged and Older Adults: A Systematic

Review. *Physical Therapy*, 98(12), 1010–1021. <https://doi.org/10.1093/ptj/pzy109>

Centro Colaborador da Organização Mundial da Saúde para a Família da Classificações

Internacionais em Português. (2015). *Classificação Internacional de Funcionalidade,*

Incapacidade e Saúde (C. M. Buchalla (ed.); 1st ed.). Editora da Universidade de São Paulo.

Cieza, A., Causey, K., Kamenov, K., Hanson, S. W., Chatterji, S., & Vos, T. (2020). Global

estimates of the need for rehabilitation based on the Global Burden of Disease study

2019: a systematic analysis for the Global Burden of Disease Study 2019. *The Lancet*,

396(10267), 2006–2017. [https://doi.org/10.1016/S0140-6736\(20\)32340-0](https://doi.org/10.1016/S0140-6736(20)32340-0)

Cornman, J. C., Gleib, D. A., & Weinstein, M. (2021). Change in Mobility: Consistency of

Estimates and Predictors Across Studies of Older Adults. *The Journals of Gerontology:*

Series B, 76(1), 209–218. <https://doi.org/10.1093/geronb/gbz091>

- Deshpande, N., Metter, E. J., Guralnik, J., Bandinelli, S., & Ferrucci, L. (2013). Predicting 3-Year Incident Mobility Disability in Middle-Aged and Older Adults Using Physical Performance Tests. *Archives of Physical Medicine and Rehabilitation*, 94(5), 994–997. <https://doi.org/10.1016/j.apmr.2012.10.032>
- do Nascimento, C. F., dos Santos, H. G., de Moraes Batista, A. F., Roman Lay, A. A., Duarte, Y. A. O., & Chiavegatto Filho, A. D. P. (2021). Cause-specific mortality prediction in older residents of São Paulo, Brazil: a machine learning approach. *Age and Ageing*, 1–7. <https://doi.org/10.1093/ageing/afab067>
- Duim, E., Lebrão, M. L., & Antunes, J. L. F. (2017). Walking speed of older people and pedestrian crossing time. *Journal of Transport & Health*, 5(February), 70–76. <https://doi.org/10.1016/j.jth.2017.02.001>
- Edwards, N., & Dulai, J. (2018). Examining the relationships between walkability and physical activity among older persons: what about stairs? *BMC Public Health*, 18(1), 1025. <https://doi.org/10.1186/s12889-018-5945-0>
- Fernández, A., García, S., Galar, M., Prati, R. C., Krawczyk, B., & Herrera, F. (2018). *Learning from Imbalanced Data Sets*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-98074-4>
- Gomez, F., Wu, Y. Y., Auais, M., Vafaei, A., & Zunzunegui, M.-V. (2017). A Simple Algorithm to Predict Falls in Primary Care Patients Aged 65 to 74 Years: The International Mobility in Aging Study. *Journal of the American Medical Directors Association*, 18(9), 774–779. <https://doi.org/10.1016/j.jamda.2017.03.021>
- Guralnik, J. M., Simonsick, E. M., Ferrucci, L., Glynn, R. J., Berkman, L. F., Blazer, D. G., Scherr, P. A., & Wallace, R. B. (1994). A Short Physical Performance Battery Assessing

- Lower Extremity Function: Association With Self-Reported Disability and Prediction of Mortality and Nursing Home Admission. *Journal of Gerontology*, 49(2), M85–M94.
<https://doi.org/10.1093/geronj/49.2.M85>
- Guralnik, Jack M., & Ferrucci, L. (2003). Assessing the building blocks of function: Utilizing measures of functional limitation. *American Journal of Preventive Medicine*, 25(3), 112–121. [https://doi.org/10.1016/S0749-3797\(03\)00174-0](https://doi.org/10.1016/S0749-3797(03)00174-0)
- Guralnik, Jack M., Ferrucci, L., Balfour, J. L., Volpato, S., & Di Iorio, A. (2001). Progressive versus Catastrophic Loss of the Ability to Walk: Implications for the Prevention of Mobility Loss. *Journal of the American Geriatrics Society*, 49(11), 1463–1470.
<https://doi.org/10.1046/j.1532-5415.2001.4911238.x>
- Hartvigsen, J., Hancock, M. J., Kongsted, A., Louw, Q., Ferreira, M. L., Genevay, S., Hoy, D., Karppinen, J., Pransky, G., Sieper, J., Smeets, R. J., Underwood, M., Buchbinder, R., Hartvigsen, J., Cherkin, D., Foster, N. E., Maher, C. G., Underwood, M., van Tulder, M., ... Woolf, A. (2018). What low back pain is and why we need to pay attention. *The Lancet*, 391(10137), 2356–2367. [https://doi.org/10.1016/S0140-6736\(18\)30480-X](https://doi.org/10.1016/S0140-6736(18)30480-X)
- Hernandez, M. E., Goldberg, A., & Alexander, N. B. (2010). Decreased Muscle Strength Relates to Self-Reported Stooping, Crouching, or Kneeling Difficulty in Older Adults. *Physical Therapy*, 90(1), 67–74. <https://doi.org/10.2522/ptj.20090035>
- Hicks, G. E., Shardell, M., Alley, D. E., Miller, R. R., Bandinelli, S., Guralnik, J., Lauretani, F., Simonsick, E. M., & Ferrucci, L. (2012). Absolute Strength and Loss of Strength as Predictors of Mobility Decline in Older Adults: The InCHIANTI Study. *The Journals of Gerontology Series A: Biological Sciences and Medical Sciences*, 67A(1), 66–73.
<https://doi.org/10.1093/gerona/glr055>

- Hu, B., Dixon, P. C., Jacobs, J. V., Dennerlein, J. T., & Schiffman, J. M. (2018). Machine learning algorithms based on signals from a single wearable inertial sensor can detect surface- and age-related differences in walking. *Journal of Biomechanics*, 71, 37–42. <https://doi.org/10.1016/j.jbiomech.2018.01.005>
- Icaza, M. G., & Albala, C. (1999). Minimental State Examination (MMSE) del estudio de dementia en Chile: análisis estadístico. *Investigaciones En Salud Pública - Documentos Técnicos*, 7, 1–18.
- Jennings, C. A., Yun, L., Loitz, C. C., Lee, E. Y., & Mummery, W. K. (2017). A Systematic Review of Interventions to Increase Stair Use. *American Journal of Preventive Medicine*, 52(1), 106–114. <https://doi.org/10.1016/j.amepre.2016.08.014>
- Kheirkhahan, M., Tudor-Locke, C., Axtell, R., Buman, M. P., Fielding, R. A., Glynn, N. W., Guralnik, J. M., King, A. C., White, D. K., Miller, M. E., Siddique, J., Brubaker, P., Rejeski, W. J., Ranshous, S., Pahor, M., Ranka, S., & Manini, T. M. (2016). Actigraphy features for predicting mobility disability in older adults. *Physiological Measurement*, 37(10), 1813–1833. <https://doi.org/10.1088/0967-3334/37/10/1813>
- Latham, K. (2014). Racial and Educational Disparities in Mobility Limitation Among Older Women: What Is the Role of Modifiable Risk Factors? *The Journals of Gerontology Series B: Psychological Sciences and Social Sciences*, 69(5), 772–783. <https://doi.org/10.1093/geronb/gbu028>
- Lebrão, M. L., Duarte, Y. A. de O., Santos, J. L. F., & Silva, N. N. da. (2018). 10 Years of SABE Study: background, methodology and organization of the study. *Revista Brasileira de Epidemiologia*, 21(suppl 2). <https://doi.org/10.1590/1980-549720180002.supl.2>

- Liu, B., Hu, X., Zhang, Q., Fan, Y., Li, J., Zou, R., Zhang, M., Wang, X., & Wang, J. (2016). Usual walking speed and all-cause mortality risk in older people: A systematic review and meta-analysis. *Gait & Posture*, 44, 172–177.
<https://doi.org/10.1016/j.gaitpost.2015.12.008>
- Loh, E. (2018). Medicine and the rise of the robots: a qualitative review of recent advances of artificial intelligence in health. *BMJ Leader*, 2(2), 59–63. <https://doi.org/10.1136/leader-2018-000071>
- Lundberg, S. M., & Lee, S.-I. (2017). A Unified Approach to Interpreting Model Predictions. *Advances in Neural Information Processing Systems*, 4765–4774.
- Musich, S., Wang, S. S., Ruiz, J., Hawkins, K., & Wicker, E. (2018). The impact of mobility limitations on health outcomes among older adults. *Geriatric Nursing*, 39(2), 162–169.
<https://doi.org/10.1016/j.gerinurse.2017.08.002>
- Nagi, S. Z. (1976). An Epidemiology of Disability among Adults in the United States. *The Milbank Memorial Fund Quarterly. Health and Society*, 54(4), 439.
<https://doi.org/10.2307/3349677>
- Odden, M. C., & Melzer, D. (2019). Machine Learning in Aging Research. *The Journals of Gerontology: Series A*, 74(12), 1901–1902. <https://doi.org/10.1093/gerona/glz074>
- Olaya, B., Moneta, M. V., Doménech-Abella, J., Miret, M., Bayes, I., Ayuso-Mateos, J. L., & Haro, J. M. (2018). Mobility Difficulties, Physical Activity, and All-cause Mortality Risk in a Nationally representative Sample of Older Adults. *The Journals of Gerontology: Series A*, 73(9), 1272–1279. <https://doi.org/10.1093/gerona/glx121>
- Paradela, E. M. P., Lourenço, R. A., & Veras, R. P. (2005). Validation of geriatric depression scale in a general outpatient clinic. *Revista de Saúde Pública*, 39(6), 918–923.

<https://doi.org/10.1590/S0034-89102005000600008>

PyCaret.org. (2020). *PyCaret*. PyCaret Version 1.0.0. <https://pycaret.org/about>

Rajkomar, A., Dean, J., & Kohane, I. (2019). Machine Learning in Medicine. *New England Journal of Medicine*, 380(14), 1347–1358. <https://doi.org/10.1056/NEJMra1814259>

Rantakokko, M., Mänty, M., & Rantanen, T. (2013). Mobility Decline in Old Age. *Exercise and Sport Sciences Reviews*, 41(1), 19–25.
<https://doi.org/10.1097/JES.0b013e3182556f1e>

Rose, S. (2013). Mortality risk score prediction in an elderly population using machine learning. *American Journal of Epidemiology*, 177(5), 443–452.
<https://doi.org/10.1093/aje/kws241>

Santos, H. G. dos, Nascimento, C. F. do, Izbicki, R., Duarte, Y. A. de O., & Porto Chiavegatto Filho, A. D. (2019). Machine learning para análises preditivas em saúde: exemplo de aplicação para predizer óbito em idosos de São Paulo, Brasil. *Cadernos de Saúde Pública*, 35(7), 1–16. <https://doi.org/10.1590/0102-311x00050818>

Santos, H. G. dos, Zampieri, F. G., Normilio-Silva, K., Silva, G. T. da, Lima, A. C. P. de, Cavalcanti, A. B., & Chiavegatto Filho, A. D. P. (2020). Machine learning to predict 30-day quality-adjusted survival in critically ill patients with cancer. *Journal of Critical Care*, 55, 73–78. <https://doi.org/10.1016/j.jcrc.2019.10.015>

Seidel, D., Brayne, C., & Jagger, C. (2011). Limitations in physical functioning among older people as a predictor of subsequent disability in instrumental activities of daily living. *Age and Ageing*, 40(4), 463–469. <https://doi.org/10.1093/ageing/afr054>

Shung, D. L., Au, B., Taylor, R. A., Tay, J. K., Laursen, S. B., Stanley, A. J., Dalton, H. R., Ngu, J., Schultz, M., & Laine, L. (2020). Validation of a Machine Learning Model That

Outperforms Clinical Risk Scoring Systems for Upper Gastrointestinal Bleeding.

Gastroenterology, 158(1), 160–167. <https://doi.org/10.1053/j.gastro.2019.09.009>

Speiser, J. L., Callahan, K. E., Houston, D. K., Fanning, J., Gill, T. M., Guralnik, J. M.,

Newman, A. B., Pahor, M., Rejeski, W. J., & Miller, M. E. (2020). Machine Learning in

Aging: An Example of Developing Prediction Models for Serious Fall Injury in Older

Adults. *The Journals of Gerontology: Series A*, XX(Xx), 1–8.

<https://doi.org/10.1093/gerona/glaa138>

Stringhini, S., Carmeli, C., Jokela, M., Avendaño, M., McCrory, C., D’Errico, A., Bochud,

M., Barros, H., Costa, G., Chadeau-Hyam, M., Delpierre, C., Gandini, M., Fraga, S.,

Goldberg, M., Giles, G. G., Lassale, C., Kenny, R. A., Kelly-Irving, M., Paccaud, F., ...

Kivimäki, M. (2018). Socioeconomic status, non-communicable disease risk factors, and

walking speed in older adults: multi-cohort population based study. *BMJ*, 360, k1046.

<https://doi.org/10.1136/bmj.k1046>

Wallace, M. L., Buysse, D. J., Redline, S., Stone, K. L., Ensrud, K., Leng, Y., Ancoli-Israel,

S., & Hall, M. H. (2019). Multidimensional Sleep and Mortality in Older Adults: A

Machine-Learning Comparison With Other Risk Factors. *The Journals of Gerontology:*

Series A, 74(12), 1903–1909. <https://doi.org/10.1093/gerona/glz044>

Ye, C., Li, J., Hao, S., Liu, M., Jin, H., Zheng, L., Xia, M., Jin, B., Zhu, C., Alfreds, S. T.,

Stearns, F., Kanov, L., Sylvester, K. G., Widen, E., McElhinney, D., & Ling, X. B.

(2020). Identification of elders at higher risk for fall with statewide electronic health

records and a machine learning algorithm. *International Journal of Medical Informatics*,

137(February), 104105. <https://doi.org/10.1016/j.ijmedinf.2020.104105>

Table 1: The sample included in each prediction and the number of individuals that presented the outcomes in the follow-up.

Outcome	Number of individuals included	Presented the outcome in the follow-up	
		N	%
Total mobility decline ^a	720	347	48.2
Limitation in walking	1401	268	19.1
Limitation in climbing stairs	1277	326	25.5
Limitation in carrying weights	1235	370	30.0
Limitation in crouching and kneeling	930	295	31.7

^aComposite outcome - limitation in any of the 4 tasks

Table 2: Performance metrics of the best algorithms for the test set.

	Best algorithm	AUC-ROC[CI]	Threshold 50%		Optimal threshold ^a	
			Sensitivity[CI]	Specificity[CI]	Sensitivity[CI]	Specificity[CI]
Total mobility	Random Forest	0.75[0.69-0.80]	0.67[0.58-0.76]	0.71[0.63-0.80]	0.60[0.51-0.69]	0.81[0.74-0.88]
Walking	SVM Radial	0.78[0.74-0.83]	0.70[0.60-0.80]	0.75[0.70-0.79]	0.67[0.56-0.77]	0.81[0.77-0.85]
Climbing stairs	Random Forest	0.79[0.74-0.83]	0.59[0.49-0.69]	0.80[0.76-0.85]	0.73[0.65-0.82]	0.74[0.69-0.79]
Carrying weights	Random Forest	0.80[0.75-0.84]	0.62[0.53-0.71]	0.80[0.75-0.85]	0.80[0.73-0.88]	0.70[0.65-0.76]
Crouching, kneeling	Random Forest	0.81[0.76-0.85]	0.67[0.58-0.77]	0.76[0.70-0.82]	0.79[0.70-0.87]	0.77[0.66-0.79]

^aThe optimal threshold for mobility decline = 0.5219, for limitation in walking = 0.5303, in climbing stairs = 0.4537, in carrying

weights = 0.4275, and in crouching, kneeling = 0.4723.

Figure 1: Receiver Operating Characteristic (ROC) curves for the test set of the three best algorithms of each outcome analyzed.

Figure 2: The top five predictors according to SHAP values for each outcome analyzed by the best algorithms: (a) total mobility decline; (b) limitation in walking; (c) limitation in climbing stairs; (d) limitation in carrying weights; (e) limitation in stopping, crouching and kneeling.

Supplement

Supplementary Table 1: Characterization of samples for each outcome analyzed.

Predictors	Total mobility		Walking		Climbing stairs		Carrying weights		Crouching, kneeling	
	n	%	n	%	n	%	n	%	n	%
Female gender	354	49.2	880	62.8	759	59.4	686	55.5	510	54.8
Age (Mean, SD)	67.12	7.07	68.16	7.45	67.27	7.09	67.80	7.43	67.35	7.33
Schooling										
Up to 3 years	257	35.7	605	43.2	491	38.4	491	39.8	354	38.1
4-7 years	277	38.5	503	35.9	482	37.7	450	36.4	341	36.7
8 years or more	177	24.6	277	19.8	286	22.4	276	22.3	222	23.9
Falls in the last 12 months										
None	565	78.5	1035	73.9	967	75.7	935	75.7	722	77.6
One	109	15.1	207	14.8	203	15.9	188	15.2	141	15.2
Two or more	44	6.1	151	10.8	103	8.1	106	8.6	65	7.0
Smoking										
Never smoking	371	51.5	772	55.1	679	53.2	639	51.7	483	51.9
Former smoking	245	34.0	432	30.8	419	32.8	415	33.6	318	34.2
Current smoking	104	14.4	197	14.1	279	21.8	181	14.7	129	13.9
Race/skin color										
White	457	63.5	893	63.7	810	63.4	780	63.2	576	61.9
Mixed	176	24.4	355	25.3	331	25.9	318	25.7	248	26.7
Black	37	5.1	76	5.4	66	5.2	68	5.5	49	5.3
Other	49	6.8	76	5.4	69	5.4	68	5.5	56	6.0
Alcohol consumption per week										
Less than 1 day	525	72.9	1129	80.6	993	77.8	945	76.5	703	75.6

1-3 days	133	18.5	192	13.7	200	15.7	196	15.9	154	16.6
4 or more days	62	8.6	80	5.7	84	6.6	94	7.6	73	7.8
BMI (Mean, SD)	24.69	7.56	25.80	7.83	25.56	7.66	25.76	7.64	25.07	7.54
Hypertension	305	42.4	725	51.7	641	50.2	618	50.0	421	45.3
Diabetes mellitus	99	13.8	228	16.3	207	16.2	191	15.5	134	14.4
Pulmonary disease	42	5.8	101	7.2	78	6.1	73	5.9	56	6.0
Heart disease	83	11.5	202	14.4	163	12.8	162	13.1	116	12.5
Stroke	9	1.3	60	4.3	45	3.5	38	3.1	20	2.2
Arthrosis or arthritis	86	11.9	342	24.4	268	21.0	256	20.7	132	14.2
Osteoporosis	47	6.5	196	14.0	150	11.7	129	10.4	76	8.2
Chest pain in the last 12 months	100	13.9	293	20.9	224	17.5	212	17.2	156	16.8
Back pain in the last 12 months	128	17.8	463	33.0	362	28.3	320	25.9	195	21.0
Edema in the last 12 months	98	13.6	361	25.8	271	21.2	275	22.3	161	17.3
Severe fatigue or tiredness in the last 12 months	66	9.2	264	18.8	189	14.8	173	14.0	115	12.4
Used antidepressants in the last 12 months										
Without depression	640	88.9	1177	84.0	1092	85.5	1061	85.9	808	86.9
Did not take	54	7.5	136	9.7	116	9.1	117	9.5	76	8.2
Yes	26	3.6	88	6.3	69	5.4	57	4.6	46	4.9
Income is sufficient	324	45.0	511	36.5	517	40.5	489	39.6	403	43.3
Cognitive deficit	38	5.3	102	7.3	71	5.6	76	6.2	67	7.2
Living alone	80	11.1	180	12.8	162	12.7	1084	87.8	117	12.6
The 15 items of GDS										
1. Are you basically satisfied with your life? (no)	79	11.0	195	13.9	218	17.1	148	12.0	115	12.4
2. Have you dropped many of your activities and interests? (yes)	92	12.8	277	19.8	218	17.1	190	15.4	139	14.9
3. Do you feel that your life is empty? (yes)	134	18.6	373	26.6	311	24.4	286	23.2	200	21.5

4. Do you often get bored? (yes)	143	19.9	386	27.6	327	25.6	284	23.0	213	22.9
5. Are you in good spirits most of the time? (no)	77	10.7	215	15.3	169	13.2	158	12.8	115	12.4
6. Are you afraid that something bad is going to happen to you? (yes)	175	24.3	417	29.8	360	28.2	335	27.1	234	25.2
7. Do you feel happy most of the time? (no)	74	10.3	195	13.9	161	12.6	145	11.7	105	11.3
8. Do you often feel helpless? (yes)	49	6.8	151	10.8	110	8.6	102	8.3	77	8.3
9. Do you prefer to stay at home, rather than going out and doing new things? (yes)	232	32.2	562	40.1	479	37.5	477	38.6	322	34.6
10. Do you feel you have more problems with memory than most? (yes)	48	6.7	147	10.5	114	8.9	104	8.4	74	8.0
11. Do you think it is wonderful to be alive now? (no)	11	1.5	36	2.6	28	2.2	27	2.2	17	1.8
12. Do you feel pretty worthless the way you are now? (yes)	44	6.1	146	10.4	111	8.7	104	8.4	71	7.6
13. Do you feel full of energy? (no)	58	8.1	197	14.1	146	11.4	139	11.3	84	9.0
14. Do you feel that your situation is hopeless? (yes)	64	8.9	209	14.9	150	11.7	144	11.7	91	9.8
15. Do you think that most people are better off than you are? (yes)	177	24.6	395	28.2	332	26.0	322	26.1	235	25.3

BMI: Body mass index; SD: Standard deviation

Supplementary Table 2: Distribution of samples according to the outcomes, n(%).

Predictors	Limitation in any mobility task, n=720.			Limitation in walking, n=1,401.			Limitation in climbing stairs, n=1,277.			Limitation in carrying weights, n=1,235.			Limitation in crouching, kneeling, n=930.		
	No	Yes	p-value*	No	Yes	p-value*	No	Yes	p-value*	No	Yes	p-value*	No	Yes	p-value*
Gender															
Female	165(22.9)	189(26.2)	0.008	679(77.1)	201(22.8)	<0.001	541(71.3)	218(28.7)	0.002	431(62.8)	255(37.2)	<0.001	333(65.3)	177(34.7)	0.037
Male	208(28.9)	158(21.9)		454(87.1)	67(12.8)		410(79.2)	108(20.8)		434(79.1)	115(20.9)		302(71.9)	118(28.1)	
Age (Mean, SD)	65.2(5.4)	69.2(8.0)	<0.001	67.1(6.8)	72.7(8.3)	<0.001	65.6(5.9)	72.3(7.9)	<0.001	65.9(6.3)	72.2(8.0)	<0.001	65.7(6.3)	70.9(8.1)	<0.001
Schooling															
Up to 3 years	101(39.3)	156(60.7)	<0.001	447(73.8)	158(26.1)	<0.001	312(63.5)	179(36.5)	<0.001	279(56.8)	212(43.2)	<0.001	201(56.8)	153(43.2)	<0.001
4-7 years	160(57.8)	117(42.2)		430(85.4)	73(14.5)		374(77.6)	108(22.4)		347(77.1)	103(22.9)		255(74.8)	86(25.2)	
8 years or more	108(61.0)	69(39.0)		246(88.8)	31(11.1)		248(86.7)	38(13.3)		224(81.2)	52(18.8)		169(76.1)	53(23.9)	
Falls in the last 12 months															
None	309(54.7)	256(45.3)	0.003	862(83.2)	173(16.7)	<0.001	735(76.0)	232(24.0)	0.015	668(71.4)	267(28.6)	0.012	507(70.2)	215(29.8)	0.015
One	48(44.0)	61(56.0)		156(75.3)	51(24.6)		148(72.9)	55(27.1)		133(70.7)	55(29.3)		91(64.5)	50(35.5)	
Two or more	14(31.8)	30(61.2)		108(71.5)	43(28.4)		65(63.1)	38(36.9)		61(57.5)	45(42.5)		35(53.8)	30(46.2)	
Smoking															
Never somking	187(50.4)	184(49.6)	0.521	608(78.7)	164(21.2)	0.083	486(71.6)	193(28.4)	0.038	424(66.4)	215(33.6)	0.014	308(63.8)	175(36.2)	0.007
Former smoking	127(51.8)	118(48.2)		360(83.3)	72(16.6)		324(77.3)	95(22.7)		307(74.0)	108(26.0)		236(74.2)	82(25.8)	
Current smoking	59(56.7)	45(43.3)		165(83.7)	32(16.2)		141(78.8)	38(21.2)		134(74.0)	47(26.0)		91(70.5)	38(29.5)	
Race/skin color															
White	225(49.2)	232(50.8)	0.214	721(80.7)	172(19.2)	0.766	586(72.3)	224(27.7)	0.088	523(67.1)	257(32.9)	0.013	374(64.9)	202(35.1)	0.032
Mixed	103(58.2)	73(41.5)		292(82.2)	63(17.7)		262(79.2)	69(20.8)		245(77)	73(23)		186(75)	62(25)	
Black	20(54.1)	17(45.9)		60(78.9)	16(21.0)		52(78.8)	14(21.2)		48(70.6)	20(29.4)		36(73.5)	13(26.5)	
Other	25(51.0)	24(49.0)		59(77.6)	17(22.3)		50(72.5)	19(27.5)		48(70.6)	20(29.4)		39(69.6)	17(30.4)	
Alcohol consumption per week															
Less than 1 day	254(48.4)	271(51.6)	0.008	892(79.0)	237(20.9)	0.001	718(72.3)	275(27.7)	0.003	633(67)	312(33)	0.000	471(67)	232(33)	0.144
1-3 days	79(59.3)	54(40.6)		171(89.0)	21(10.9)		162(81.0)	38(19.0)		155(79.1)	41(20.9)		107(69.5)	47(30.5)	
4 or more days	40(64.5)	22(35.5)		70(87.5)	10(12.5)		71(84.5)	13(15.5)		77(81.9)	17(18.1)		57(78.1)	16(21.9)	
BMI (Mean, SD)	24.7(7.2)	24.7(8.0)	0.950	25.7(7.6)	26.1(8.6)	0.586	25.8(7.4)	25.0(8.4)	0.132	25.9(7.6)	25.5(7.8)	0.417	25.3(7.3)	24.6(8.0)	0.218
Hypertension															
Yes	141(46.2)	164(53.8)	0.013	559(77.1)	166(22.8)	<0.001	453(70.7)	188(29.3)	0.002	416(67.3)	202(32.7)	0.042	276(65.6)	145(34.4)	0.121

Yes	21(31.8)	45(68.1)	0.001	187(70.8)	77(29.1)	<0.001	126(66.7)	63(33.3)	0.010	105(60.7)	68(39.3)	0.005	68(59.1)	47(40.9)	0.032
No	352(53.8)	302(46.1)		946(83.2)	191(16.7)		825(75.8)	263(24.2)		760(71.6)	302(28.4)		567(69.6)	248(30.4)	
Antidepressants in the last 12 months															
Without depression	333(52.0)	307(47.9)	0.597	958(81.3)	219(18.6)	0.133	807(73.9)	285(26.1)	0.381	744(70.1)	317(29.9)	0.980	559(69.2)	249(30.8)	0.310
Did not take	29(53.7)	25(46.2)		111(81.6)	25(18.3)		88(75.9)	28(24.1)		81(69.2)	36(30.8)		47(61.8)	29(38.2)	
Yes	11(42.3)	15(57.6)		64(72.7)	24(27.2)		56(81.2)	13(18.8)		40(70.2)	17(29.8)		29(63)	17(37)	
Income is sufficient															
Yes	173(53.3)	151(46.6)	0.510	429(83.9)	82(16.0)	0.029	400(77.4)	117(22.6)	0.067	362(74)	127(26)	0.015	297(73.7)	106(26.3)	0.003
No	198(50.6)	193(49.3)		697(79.0)	185(20.9)		547(72.6)	206(27.4)		497(67.3)	241(32.7)		336(64.2)	187(35.8)	
Cognitive deficit															
Yes	9(23.6)	29(76.3)	0.001	55(53.9)	47(46.0)	<0.001	37(52.1)	34(47.9)	<0.001	36(47.4)	40(52.6)	<0.001	29(43.3)	38(56.7)	<0.001
No	364(53.3)	318(46.6)		1078(82.9)	221(17.0)		914(75.8)	292(24.2)		829(71.5)	330(28.5)		606(70.2)	257(29.8)	
Living alone															
Yes	36(45)	44(55)	0.241	146(81.1)	34(18.8)	1.000	115(71.0)	47(29.0)	0.321	94(62.3)	57(37.7)	0.033	556(68.4)	257(31.6)	0.935
No	337(52.6)	303(47.3)		987(80.8)	234(19.1)		836(75.0)	279(25.0)		771(71.1)	313(28.9)		79(67.5)	38(32.5)	
The 15 items of GDS															
1. Are you basically satisfied with your life? (no)															
Yes	36(45.5)	43(54.4)	0.231	146(74.8)	49(25.1)	0.003	126(74.6)	43(25.4)	0.909	101(68.2)	47(31.8)	0.457	75(65.2)	40(34.8)	0.270
No	327(53.4)	285(46.5)		946(83.8)	182(16.1)		793(75.3)	260(24.7)		736(71.6)	292(28.4)		540(70.8)	223(29.2)	
2. Have you dropped many of your activities and interests? (yes)															
Yes	42(45.7)	50(54.3)	0.160	206(74.3)	71(25.6)	<0.001	153(70.2)	65(29.8)	0.055	129(67.9)	61(32.1)	0.322	91(65.5)	48(34.5)	0.259
No	328(54.1)	278(45.9)		904(84.8)	162(15.1)		780(76.6)	238(23.4)		719(71.8)	283(28.2)		528(70.7)	219(29.3)	
3. Do you feel that your life is empty? (yes)															
Yes	308(55.2)	249(44.7)	0.024	283(75.8)	90(24.1)	0.000	224(72.0)	87(28.0)	0.108	185(64.7)	101(35.3)	0.005	132(66)	68(34)	0.135
No	59(44.0)	75(55.9)		810(85.0)	142(14.9)		701(76.8)	212(23.2)		654(73.6)	235(26.4)		484(71.8)	190(28.2)	
4. Do you often get bored? (yes)															
Yes	67(46.8)	76(53.1)	0.143	302(78.8)	81(21.1)	0.024	238(72.8)	89(27.2)	0.200	191(67.3)	93(32.7)	0.113	139(65.3)	74(34.7)	0.114

No	300(54.1)	254(45.8)		804(84.1)	151(15.8)		695(76.5)	213(23.5)		655(72.4)	250(27.6)		479(71.3)	193(28.7)	
5. Are you in good spirits most of the time? (no)															
Yes	35(45.4)	42(54.5)	0.196	162(75.3)	53(24.6)	0.002	129(76.3)	40(23.7)	0.928	101(63.9)	57(36.1)	0.030	74(64.3)	41(35.7)	0.170
No	332(53.9)	283(46.0)		933(84.2)	174(15.7)		796(75.7)	256(24.3)		741(72.6)	279(27.4)		542(71.1)	220(28.9)	
6. Are you afraid that something bad is going to happen to you? (yes)															
Yes	78(44.5)	97(55.4)	0.012	322(77.2)	95(22.7)	0.001	265(73.6)	95(26.4)	0.340	221(66)	114(34)	0.016	151(64.5)	83(35.5)	0.041
No	291(55.8)	230(44.1)		784(85.0)	138(14.9)		666(76.4)	206(23.6)		625(73.2)	229(26.8)		467(72)	182(28)	
7. Do you feel happy most of the time? (no)															
Yes	35(47.2)	39(52.7)	0.399	148(75.8)	47(24.1)	0.010	124(77.0)	37(23.0)	0.783	101(69.7)	44(30.3)	0.677	69(65.7)	36(34.3)	0.328
No	329(53.2)	289(46.7)		940(83.7)	182(16.2)		799(75.7)	257(24.3)		738(71.7)	291(28.3)		546(70.9)	224(29.1)	
8. Do you often feel helpless? (yes)															
Yes	19(38.7)	30(61.2)	0.059	118(78.1)	33(21.8)	0.170	79(71.8)	31(28.2)	0.409	57(55.9)	45(44.1)	0.000	49(63.6)	28(36.4)	0.250
No	350(53.8)	300(46.1)		983(83.0)	201(16.9)		852(75.9)	271(24.1)		791(72.8)	295(27.2)		570(70.6)	237(29.4)	
9. Do you prefer to stay at home, rather than going out and doing new things? (yes)															
Yes	112(48.2)	120(51.7)	0.114	446(79.3)	116(20.6)	0.012	354(73.9)	125(26.1)	0.364	326(68.3)	151(31.7)	0.081	214(66.5)	108(33.5)	0.111
No	256(54.9)	210(45.0)		658(84.7)	118(15.2)		575(76.4)	178(23.6)		519(73.2)	190(26.8)		405(71.8)	159(28.2)	
10. Do you feel you have more problems with memory than most? (yes)															
Yes	20(41.6)	28(58.3)	0.114	110(74.8)	37(25.1)	0.004	75(65.8)	39(34.2)	0.007	64(61.5)	40(38.5)	0.017	47(63.5)	27(36.5)	0.218
No	327(54.2)	276(45.7)		925(84.7)	167(15.2)		806(77.6)	233(22.4)		733(73.1)	270(26.9)		539(71.1)	219(28.9)	
11. Do you think it is wonderful to be alive now? (no)															
Yes	5(45.4)	6(54.5)	0.846	25(69.4)	11(30.5)	0.062	20(71.4)	8(28.6)	0.779	15(55.6)	12(44.4)	0.097	9(52.9)	8(47.1)	0.185

No	360(53.0)	319(46.9)		1068(82.8)	221(17.1)		900(75.6)	291(24.4)		826(72)	321(28)		605(70.8)	250(29.2)	
12. Do you feel pretty worthless the way you are now? (yes)															
Yes	13(29.5)	31(70.4)	0.002	107(73.2)	39(26.7)	0.002	72(64.9)	39(35.1)	0.006	65(62.5)	39(37.5)	0.046	38(53.5)	33(46.5)	0.002
No	355(54.7)	293(45.2)		990(83.8)	190(16.1)		857(77.0)	256(23.0)		777(72.3)	298(27.7)		579(71.8)	227(28.2)	
13. Do you feel full of energy? (no)															
Yes	27(46.5)	31(53.4)	0.379	130(65.9)	67(34.0)	<0.001	101(69.2)	45(30.8)	0.070	86(61.9)	53(38.1)	0.012	55(65.5)	29(34.5)	0.372
No	343(53.5)	298(46.4)		962(85.5)	162(14.4)		824(76.4)	254(23.6)		756(72.6)	286(27.4)		563(70.8)	232(29.2)	
14. Do you feel that your situation is hopeless? (yes)															
Yes	28(43.7)	36(56.2)	0.178	156(74.6)	53(25.3)	0.002	101(67.3)	49(32.7)	0.018	78(54.2)	66(45.8)	<0.001	56(61.5)	35(38.5)	0.084
No	335(53.4)	292(46.5)		932(83.8)	179(16.1)		820(76.6)	251(23.4)		759(73.7)	271(26.3)		556(70.9)	228(29.1)	
15. Do you think that most people are better off than you are? (yes)															
Yes	91(51.4)	86(48.5)	0.484	313(79.2)	82(20.7)	0.050	243(73.2)	89(26.8)	0.098	221(68.6)	101(31.4)	0.073	170(72.3)	65(27.7)	0.880
No	215(54.9)	176(45.0)		584(84.1)	110(15.8)		535(78.1)	150(21.9)		486(74.3)	168(25.7)		351(71.5)	140(28.5)	

BMI: Body mass index; SD: Standard deviation; *p-value corresponding to qui-square or t-test.

Supplementary Table 3: Average performance metrics of each algorithm in training set.

Outcome	Model	Accuracy	AUC	Recall	Specificity	Prec.	F1	Kappa	Hosmer_lemeshow	Spiegelhalter	Scaled_brier
Mobility decline (limitation in any of the 4 tasks)	Extra Trees Classifier	0.655	0.723[0.663-0.782]	0.632	0.678	0.662	0.640	0.310	0.187	0.335	0.132
	Random Forest Classifier	0.640	0.691[0.646-0.736]	0.594	0.686	0.657	0.619	0.279	0.407	0.342	0.085
	CatBoost Classifier	0.628	0.674[0.612-0.737]	0.594	0.663	0.634	0.608	0.257	0.222	0.321	0.076
	Gradient Boosting Classifier	0.634	0.658[0.597-0.719]	0.590	0.678	0.644	0.612	0.268	0.115	0.206	0.024
	Light Gradient Boosting Machine	0.617	0.657[0.599-0.716]	0.621	0.613	0.612	0.612	0.234	0.075	0.088	-0.035
	Ridge Classifier	0.620	0.655[0.608-0.703]	0.578	0.663	0.628	0.594	0.241	0.000	0.000	0.000
	SVM	0.609	0.655[0.607-0.704]	0.556	0.663	0.623	0.584	0.218	0.397	0.491	0.073
	Linear Discriminant Analysis	0.603	0.647[0.598-0.695]	0.575	0.632	0.604	0.580	0.207	0.187	0.158	0.006
	Logistic Regression	0.600	0.645[0.597-0.693]	0.582	0.617	0.599	0.583	0.199	0.229	0.208	0.026
	Ada Boost Classifier	0.609	0.644[0.586-0.702]	0.560	0.659	0.623	0.585	0.219	0.240	0.335	0.007
	Extreme Gradient Boosting	0.603	0.640[0.555-0.724]	0.617	0.590	0.598	0.603	0.207	0.000	0.000	-0.156
	Naive Bayes	0.548	0.617[0.575-0.659]	0.218	0.877	0.639	0.318	0.095	0.000	0.000	-0.744

Limitation in walking a block	Quadratic Discriminant Analysis	0.525	0.577[0.535-0.619]	0.200	0.851	0.598	0.266	0.051	0.000	0.000	-0.863
	K Neighbors Classifier	0.565	0.576[0.528-0.623]	0.509	0.621	0.566	0.532	0.130	0.008	0.055	-0.126
	Decision Tree Classifier	0.538	0.539[0.462-0.615]	0.586	0.491	0.524	0.548	0.077	0.000	0.000	-0.848
	K Neighbors Classifier	0.881	0.999[0.996-1.001]	0.999	0.764	0.810	0.894	0.763	0.000	0.348	0.660
	Extra Trees Classifier	0.983	0.998[0.996-1.000]	0.990	0.976	0.977	0.983	0.966	0.055	0.002	0.890
	Random Forest Classifier	0.950	0.993[0.989-0.997]	0.981	0.919	0.925	0.952	0.900	0.041	0.008	0.790
	Extreme Gradient Boosting	0.935	0.987[0.982-0.992]	0.990	0.880	0.893	0.939	0.870	0.050	0.532	0.810
	Light Gradient Boosting Machine	0.938	0.985[0.979-0.991]	0.989	0.888	0.900	0.942	0.876	0.178	0.321	0.810
	CatBoost Classifier	0.938	0.982[0.976-0.989]	0.979	0.897	0.905	0.940	0.875	0.068	0.012	0.763
	Gradient Boosting Classifier	0.835	0.912[0.896-0.927]	0.868	0.802	0.814	0.840	0.670	0.179	0.106	0.507
	Decision Tree Classifier	0.894	0.894[0.878-0.909]	0.990	0.797	0.831	0.903	0.787	0.000	0.000	0.574
	SVM	0.793	0.869[0.848-0.889]	0.840	0.747	0.769	0.802	0.587	0.060	0.387	0.422

Limitation in climbing steps	Ada Boost Classifier	0.749	0.812[0.790-0.833]	0.750	0.747	0.747	0.748	0.497	0.000	0.002	0.020
	Logistic Regression	0.743	0.803[0.781-0.824]	0.773	0.714	0.730	0.750	0.487	0.216	0.309	0.276
	Ridge Classifier	0.739	0.803[0.781-0.824]	0.767	0.711	0.726	0.745	0.478	0.000	0.000	0.000
	Linear Discriminant Analysis	0.743	0.802[0.780-0.824]	0.774	0.713	0.730	0.751	0.487	0.117	0.309	0.274
	Naive Bayes	0.519	0.721[0.699-0.744]	0.989	0.049	0.511	0.673	0.038	0.000	0.000	-0.877
	Quadratic Discriminant Analysis	0.506	0.538[0.491-0.585]	0.994	0.019	0.503	0.668	0.013	0.000	0.000	-0.971
	Extra Trees Classifier	0.948	0.984[0.969-0.998]	0.939	0.956	0.955	0.946	0.896	0.155	0.060	0.796
	Random Forest Classifier	0.919	0.971[0.951-0.990]	0.932	0.905	0.909	0.918	0.838	0.131	0.110	0.685
	Extreme Gradient Boosting	0.905	0.968[0.953-0.982]	0.964	0.845	0.863	0.910	0.809	0.021	0.383	0.724
	Light Gradient Boosting Machine	0.909	0.965[0.955-0.975]	0.964	0.854	0.870	0.913	0.818	0.150	0.614	0.722
	CatBoost Classifier	0.897	0.963[0.950-0.976]	0.938	0.856	0.868	0.901	0.794	0.150	0.028	0.663
	Gradient Boosting Classifier	0.799	0.887[0.868-0.906]	0.806	0.792	0.796	0.799	0.598	0.221	0.165	0.439

	Decision Tree Classifier	0.873	0.873[0.853-0.893]	0.968	0.778	0.814	0.884	0.746	0.000	0.000	0.492
	SVM	0.759	0.840[0.823-0.857]	0.747	0.771	0.766	0.756	0.519	0.485	0.486	0.349
	K Neighbors Classifier	0.724	0.813[0.788-0.837]	0.777	0.671	0.701	0.736	0.448	0.001	0.016	0.276
	Ada Boost Classifier	0.708	0.796[0.775-0.816]	0.690	0.725	0.715	0.702	0.415	0.002	0.034	0.017
	Linear Discriminant Analysis	0.703	0.795[0.775-0.816]	0.693	0.713	0.707	0.700	0.406	0.247	0.389	0.254
	Ridge Classifier	0.705	0.795[0.775-0.815]	0.695	0.715	0.709	0.701	0.409	0.000	0.000	0.000
	Logistic Regression	0.710	0.794[0.774-0.813]	0.702	0.718	0.714	0.707	0.420	0.318	0.437	0.256
	Quadratic Discriminant Analysis	0.572	0.755[0.722-0.788]	0.940	0.205	0.547	0.687	0.144	0.000	0.000	-0.673
	Naive Bayes	0.596	0.728[0.700-0.755]	0.887	0.304	0.570	0.684	0.191	0.000	0.000	-0.445
	Extra Trees Classifier	0.912	0.965[0.936-0.994]	0.915	0.909	0.911	0.910	0.825	0.174	0.054	0.711
Limitation in carrying weights	Extreme Gradient Boosting	0.886	0.949[0.920-0.977]	0.937	0.835	0.849	0.889	0.772	0.026	0.371	0.649
	Light Gradient Boosting Machine	0.888	0.946[0.918-0.974]	0.937	0.840	0.852	0.891	0.777	0.143	0.301	0.651
	Random Forest Classifier	0.878	0.944[0.912-0.976]	0.897	0.858	0.862	0.877	0.755	0.080	0.134	0.588

Limitation in crouching and kneeling	CatBoost Classifier	0.864	0.934[0.905-0.962]	0.892	0.835	0.843	0.865	0.727	0.225	0.105	0.580
	Gradient Boosting Classifier	0.798	0.875[0.855-0.894]	0.808	0.788	0.792	0.799	0.597	0.378	0.231	0.421
	Decision Tree Classifier	0.836	0.836[0.808-0.864]	0.930	0.742	0.785	0.849	0.673	0.000	0.000	0.345
	SVM	0.750	0.823[0.805-0.841]	0.739	0.762	0.758	0.747	0.501	0.383	0.425	0.314
	Ada Boost Classifier	0.722	0.806[0.789-0.823]	0.703	0.742	0.733	0.717	0.445	0.000	0.005	0.018
	Ridge Classifier	0.717	0.793[0.780-0.805]	0.699	0.734	0.726	0.711	0.433	0.000	0.000	0.000
	Linear Discriminant Analysis	0.716	0.793[0.780-0.805]	0.699	0.732	0.725	0.711	0.431	0.430	0.397	0.249
	Logistic Regression	0.719	0.792[0.780-0.803]	0.706	0.732	0.726	0.715	0.438	0.559	0.566	0.252
	K Neighbors Classifier	0.698	0.760[0.697-0.809]	0.753	0.642	0.678	0.712	0.395	0.036	0.049	0.170
	Naive Bayes	0.571	0.715[0.686-0.745]	0.923	0.220	0.547	0.681	0.143	0.000	0.000	-0.535
	Quadratic Discriminant Analysis	0.537	0.703[0.676-0.730]	0.947	0.128	0.527	0.672	0.075	0.000	0.000	-0.827
	Extra Trees Classifier	0.881	0.938[0.898-0.979]	0.862	0.899	0.894	0.873	0.761	0.255	0.196	0.624
	Random Forest Classifier	0.856	0.915[0.870-0.961]	0.857	0.854	0.857	0.852	0.712	0.099	0.164	0.509

Light Gradient Boosting Machine	0.840	0.908[0.861-0.955]	0.896	0.784	0.805	0.845	0.680	0.034	0.285	0.502
Extreme Gradient Boosting	0.837	0.906[0.863-0.950]	0.894	0.779	0.800	0.842	0.674	0.003	0.337	0.510
CatBoost Classifier	0.831	0.902[0.864-0.940]	0.849	0.813	0.820	0.832	0.662	0.137	0.205	0.482
Gradient Boosting Classifier	0.745	0.828[0.789-0.867]	0.757	0.732	0.739	0.745	0.489	0.278	0.295	0.318
SVM	0.720	0.784[0.756-0.812]	0.705	0.734	0.730	0.714	0.439	0.272	0.403	0.239
Decision Tree Classifier	0.805	0.805[0.769-0.840]	0.903	0.707	0.757	0.820	0.610	0.000	0.000	0.221
Ada Boost Classifier	0.686	0.742[0.714-0.771]	0.678	0.694	0.690	0.682	0.372	0.048	0.087	0.012
Ridge Classifier	0.665	0.723[0.709-0.750]	0.638	0.692	0.675	0.654	0.329	0.000	0.000	0.000
Linear Discriminant Analysis	0.663	0.723[0.704-0.741]	0.638	0.690	0.674	0.653	0.327	0.265	0.320	0.137
Logistic Regression	0.671	0.722[0.704-0.739]	0.651	0.692	0.681	0.663	0.343	0.266	0.425	0.139
K Neighbors Classifier	0.660	0.714[0.656-0.773]	0.644	0.676	0.667	0.654	0.320	0.017	0.012	0.070
Quadratic Discriminant Analysis	0.638	0.702[0.660-0.745]	0.547	0.729	0.698	0.578	0.275	0.000	0.000	-0.368
Naive Bayes	0.622	0.693[0.665-0.720]	0.541	0.703	0.676	0.575	0.244	0.000	0.000	-0.280

Supplementary Table 4: Hyperparameters for the best algorithms of each outcome.

Parameters	
Total Mobility (Random Forest)	bootstrap
	ccp_alpha
	class_weight
	criterion
	max_depth
	max_features
	max_leaf_nodes
	max_samples
	min_impurity_decrease
	min_impurity_split
	min_samples_leaf
	min_samples_split
	min_weight_fraction_leaf
	n_estimators
	n_jobs
	oob_score
	random_state
	verbose
	warm_start
Walking (SVM Radial)	C
	break_ties
	cache_size
	class_weight
	coef0
	decision_function_shape
	degree
	gamma
	kernel
	max_iter
	probability
	random_state
	shrinking
	tol
	verbose
Climbing	bootstrap
	ccp_alpha
	class_weight
	criterion

	max_depth	1200
	max_features	sqrt
	max_leaf_nodes	None
	max_samples	None
	min_impurity_decrease	0
	min_impurity_split	None
	min_samples_leaf	12
	min_samples_split	3
	min_weight_fraction_leaf	0
	n_estimators	671
	n_jobs	-1
	oob_score	False
	random_state	42
	verbose	0
	warm_start	False
Carrying weights (Random Forest)	bootstrap	False
	ccp_alpha	0
	class_weight	None
	criterion	entropy
	max_depth	1200
	max_features	sqrt
	max_leaf_nodes	None
	max_samples	None
	min_impurity_decrease	0
	min_impurity_split	None
	min_samples_leaf	12
	min_samples_split	3
	min_weight_fraction_leaf	0
	n_estimators	671
	n_jobs	-1
	oob_score	False
	random_state	42
	verbose	0
	warm_start	False
Crouching, kneeling	bootstrap	False
	ccp_alpha	0
	class_weight	None
	criterion	entropy
	max_depth	1200
	max_features	sqrt
	max_leaf_nodes	None
	max_samples	None
	min_impurity_decrease	0

min_impurity_split	None
min_samples_leaf	12
min_samples_split	3
min_weight_fraction_leaf	0
n_estimators	671
n_jobs	-1
oob_score	False
random_state	42
verbose	0
warm_start	False

Supplementary Table 5: Performance metrics of each algorithm in test set.

Outcome	Model	Accuracy	AUC	Recall	Specificity	Prec.	F1	Kappa	Hosmer_lemeshow	Spiegelhalter	Scaled_brier
Mobility decline (limitation in any of the 4 tasks)	Random Forest Classifier	0.691	0.746[0.692-0.798]	0.667	0.714	0.686	0.676	0.381	0.010	0.000	0.133
	CatBoost Classifier	0.696	0.718[0.661-0.776]	0.686	0.705	0.686	0.686	0.391	0.130	0.471	0.153
	Ridge Classifier	0.641	0.718[0.661-0.771]	0.629	0.652	0.629	0.629	0.280	0.509	0.084	0.132
	Logistic Regression	0.645	0.710[0.654-0.764]	0.648	0.643	0.630	0.639	0.290	0.741	0.061	0.124
	SVM	0.622	0.706[0.647-0.761]	0.533	0.705	0.629	0.577	0.240	0.145	0.360	0.138
	Light Gradient Boosting Machine	0.673	0.703[0.647-0.760]	0.705	0.643	0.649	0.676	0.347	0.000	0.000	0.055
	Linear Discriminant Analysis	0.654	0.703[0.646-0.759]	0.657	0.652	0.639	0.648	0.309	0.177	0.006	0.107
	Naive Bayes	0.585	0.691[0.628-0.743]	0.229	0.920	0.727	0.348	0.152	0.000	0.000	-0.606
	Gradient Boosting Classifier	0.654	0.680[0.619-0.734]	0.676	0.634	0.634	0.654	0.310	0.001	0.001	0.062
	Extreme Gradient Boosting	0.641	0.676[0.619-0.734]	0.676	0.607	0.617	0.646	0.283	0.000	0.000	-0.074
	Ada Boost Classifier	0.627	0.674[0.617-0.731]	0.638	0.616	0.609	0.623	0.254	0.010	0.985	0.000

Limitation in walking a block	Extra Trees Classifier	0.654	0.657[0.599-0.719]	0.619	0.688	0.650	0.634	0.307	0.001	0.010	0.056
	Decision Tree Classifier	0.604	0.604[0.548-0.659]	0.610	0.598	0.587	0.598	0.208	0.000	0.000	-0.587
	K Neighbors Classifier	0.535	0.571[0.507-0.636]	0.410	0.652	0.524	0.460	0.062	0.000	0.000	-0.128
	Quadratic Discriminant Analysis	0.521	0.547[0.493-0.556]	0.048	0.964	0.556	0.088	0.012	0.000	0.000	-0.913
	SVM	0.741	0.784[0.736-0.828]	0.691	0.753	0.400	0.507	0.348	0.000	0.052	-0.074
	Random Forest Classifier	0.779	0.780[0.732-0.825]	0.543	0.835	0.440	0.486	0.348	0.000	0.000	-0.016
	K Neighbors Classifier	0.739	0.766[0.718-0.814]	0.654	0.759	0.393	0.491	0.330	0.000	0.088	-0.139
	Ridge Classifier	0.705	0.762[0.712-0.808]	0.691	0.709	0.360	0.470	0.297	0.000	0.104	-0.252
	Linear Discriminant Analysis	0.698	0.761[0.710-0.810]	0.691	0.700	0.354	0.469	0.287	0.000	0.001	-0.270
	Logistic Regression	0.696	0.758[0.706-0.807]	0.716	0.691	0.356	0.475	0.294	0.000	0.002	-0.277
	CatBoost Classifier	0.796	0.754[0.706-0.802]	0.333	0.906	0.458	0.386	0.267	0.005	0.068	0.085
	Gradient Boosting Classifier	0.722	0.749[0.697-0.799]	0.556	0.762	0.357	0.435	0.262	0.000	0.412	-0.103
	Ada Boost Classifier	0.689	0.731[0.677-0.783]	0.642	0.700	0.338	0.443	0.255	0.000	0.000	-0.581

	Logistic Regression	0.716	0.766[0.719-0.807]	0.622	0.748	0.459	0.528	0.332	0.000	0.258	0.000
	Linear Discriminant Analysis	0.719	0.765[0.718-0.804]	0.633	0.748	0.463	0.535	0.340	0.000	0.058	-0.004
	Ada Boost Classifier	0.714	0.756[0.705-0.798]	0.633	0.741	0.456	0.530	0.332	0.000	0.000	-0.297
	Extreme Gradient Boosting	0.745	0.748[0.703-0.790]	0.500	0.829	0.500	0.500	0.329	0.000	0.000	-0.034
	Extra Trees Classifier	0.747	0.714[0.661-0.759]	0.194	0.937	0.514	0.282	0.165	0.007	0.240	0.099
	Naive Bayes Decision Tree Classifier	0.396	0.654[0.596-0.699]	0.918	0.217	0.287	0.437	0.078	0.000	0.000	-1.834
	K Neighbors Classifier	0.690	0.618[0.568-0.663]	0.469	0.766	0.407	0.436	0.224	0.000	0.000	-0.630
	Quadratic Discriminant Analysis	0.591	0.582[0.527-0.632]	0.449	0.640	0.299	0.359	0.076	0.000	0.000	-0.531
		0.313	0.583[0.478-0.546]	0.918	0.105	0.260	0.405	0.013	0.000	0.000	-2.611
Limitation in carrying weights	Random Forest Classifier	0.747	0.796[0.754-0.838]	0.622	0.800	0.570	0.595	0.411	0.000	0.000	0.147
	Ridge Classifier	0.728	0.783[0.737-0.824]	0.676	0.750	0.540	0.600	0.396	0.000	0.211	0.101
	Linear Discriminant Analysis	0.731	0.782[0.739-0.825]	0.676	0.754	0.540	0.600	0.401	0.000	0.102	0.107
	Logistic Regression	0.733	0.781[0.738-0.824]	0.694	0.750	0.542	0.609	0.411	0.000	0.217	0.096

	Gradient Boosting Classifier	0.736	0.772[0.725-0.817]	0.631	0.781	0.551	0.588	0.395	0.000	0.131	0.123
	CatBoost Classifier	0.760	0.771[0.722-0.818]	0.586	0.835	0.602	0.594	0.424	0.000	0.062	0.177
	Ada Boost Classifier	0.722	0.769[0.722-0.814]	0.685	0.739	0.528	0.596	0.390	0.000	0.000	-0.175
	SVM	0.714	0.768[0.725-0.809]	0.640	0.746	0.518	0.573	0.362	0.000	0.077	0.082
	Extra Trees Classifier	0.720	0.752[0.707-0.798]	0.243	0.923	0.575	0.342	0.199	0.230	0.784	0.163
	Light Gradient Boosting Machine	0.722	0.737[0.686-0.787]	0.505	0.815	0.539	0.521	0.326	0.000	0.000	0.068
	Extreme Gradient Boosting	0.741	0.726[0.673-0.774]	0.523	0.835	0.574	0.547	0.367	0.000	0.000	0.020
	Naive Bayes	0.437	0.710[0.670-0.765]	0.937	0.223	0.340	0.499	0.106	0.000	0.000	-1.451
	K Neighbors Classifier	0.601	0.619[0.566-0.669]	0.550	0.623	0.384	0.452	0.154	0.000	0.000	-0.322
	Decision Tree Classifier	0.685	0.618[0.575-0.663]	0.451	0.785	0.472	0.461	0.238	0.000	0.000	-0.504
	Quadratic Discriminant Analysis	0.310	0.581[0.464-0.521]	0.937	0.042	0.295	0.448	-0.013	0.000	0.000	-2.271
Limitation in crouching and kneeling	Random Forest Classifier	0.732	0.807[0.763-0.850]	0.674	0.759	0.566	0.615	0.412	0.000	0.000	0.163
	SVM	0.721	0.773[0.726-0.816]	0.618	0.770	0.556	0.585	0.376	0.000	0.370	0.137
	CatBoost Classifier	0.729	0.771[0.724-0.819]	0.517	0.827	0.582	0.548	0.355	0.411	0.811	0.187

Ridge Classifier	0.707	0.767[0.722-0.816]	0.607	0.754	0.530	0.570	0.348	0.000	0.000	0.069
Gradient Boosting Classifier	0.718	0.750[0.699-0.800]	0.596	0.775	0.552	0.573	0.363	0.008	0.597	0.123
Linear Discriminant Analysis	0.729	0.749[0.700-0.798]	0.618	0.780	0.567	0.591	0.389	0.000	0.360	0.089
Logistic Regression	0.725	0.749[0.698-0.798]	0.607	0.780	0.563	0.584	0.379	0.000	0.564	0.083
Light Gradient Boosting Machine	0.704	0.742[0.686-0.792]	0.472	0.812	0.539	0.503	0.293	0.000	0.000	0.083
Extra Trees Classifier	0.711	0.741[0.690-0.791]	0.270	0.916	0.600	0.372	0.218	0.123	0.454	0.142
Ada Boost Classifier	0.668	0.736[0.686-0.785]	0.573	0.712	0.481	0.523	0.271	0.000	0.010	-0.141
Extreme Gradient Boosting	0.682	0.722[0.670-0.774]	0.416	0.806	0.500	0.454	0.233	0.000	0.000	-0.027
Naive Bayes	0.679	0.696[0.637-0.746]	0.517	0.754	0.495	0.506	0.268	0.000	0.000	-0.207
K Neighbors Classifier	0.621	0.646[0.587-0.700]	0.562	0.649	0.427	0.485	0.195	0.000	0.000	-0.138
Decision Tree Classifier	0.621	0.561[0.690-0.791]	0.393	0.728	0.402	0.398	0.122	0.000	0.000	-0.746
Quadratic Discriminant Analysis	0.596	0.560[0.506-0.624]	0.506	0.639	0.395	0.443	0.134	0.000	0.000	-0.737

Supplementary Figure 1: Calibration results for the best algorithms on the test set.

Supplementary Figure 2: Shapley values plots of feature importance for limitation in any mobility task (a), in walking a block (b), climbing stairs (c), carrying weights (d), and stopping, crouching and kneeling (e).

Metrics description of Supplementary Tables 3 and 5.

Accuracy is the ratio of correctly predicted observation to the total observations;

AUC is the relationship between the true positive rate and false positive rate. Higher AUC means better predictive performance;

Recall, also known as sensitivity, is the ratio of correctly predicted positive observations to all real positives.

Specificity is the ratio of correctly predicted negative observations to all real negatives.

Precision, also known as the positive predictive value, is the ratio of correctly predicted positive observations to the total observations predicted as positive.

F1 Score is the weighted average of Precision and Recall ($2 * (\text{Recall} * \text{Precision}) / (\text{Recall} + \text{Precision})$).

Kappa coefficient measures the inter-rater reliability in classification problems. Higher values mean better agreements.

Hosmer and Lemeshow is a goodness of fit test, in which a Chi-squared statistic is calculated for groups of expected and observed number of cases. P-values < 0.05 indicates poor fit and larger p-value (closer to 1) indicate a good fit.

Brier Score is the mean squared error between the actual outcome and the estimated probabilities. Values close to 0 are desired.

Spiegelhalter z test measures the model's calibration. It is a standard normal test statistic for testing whether an individual Brier score is extreme. A p-value of 1 denotes a well-calibrated model.

5 CONSIDERAÇÕES FINAIS

A mobilidade funcional é uma capacidade fundamental para a participação social dos indivíduos e um dos pilares para um envelhecimento saudável. O primeiro artigo desta tese encontrou que houve um aumento relativo da prevalência de limitação na mobilidade no período a partir do ano 2000. Esse resultado é preocupante pois evidencia que a velhice não tem sido vivida com qualidade e saúde.

A última onda do Estudo SABE analisada apresentou uma tendência de melhora nessa condição. Embora ainda inconclusivo, é possível que seja um reflexo de uma melhora nas condições socioeconômicas durante o período, como pode ser observado pela melhoria das variáveis de escolaridade e percepção de suficiência de renda. Nesse estudo também foi observado que as DCNT são importantes características associadas à limitação na mobilidade, o que evidencia a importância do rastreio e manejo adequado desses indivíduos. Verificou-se uma associação particularmente forte com o AVC, as doenças osteoarticulares e a dor lombar, o que reforça a necessidade de acesso aos serviços de reabilitação como uma forma de prevenção ou redução das incapacidades.

Como aponta a literatura, o comprometimento da mobilidade funcional está associado a uma menor sobrevida, e pior condição de saúde geral, de modo que testes de avaliação da mobilidade têm sido descritos na literatura como formas de triagem de idosos frágeis na prática clínica. Um dos métodos mais simples de avaliar aspectos da mobilidade e mais mencionados na literatura como preditor de óbito em idosos, é o tempo de caminhada. No segundo artigo desta tese observou-se que o teste de levantar e sentar de uma cadeira 5 vezes foi um preditor mais forte do que a velocidade da marcha, contrariando achados em outras populações. É possível que a caminhada em distâncias curtas reduza a sensibilidade do teste, mas isso aponta para o fato de que o teste de levantar e sentar talvez seja a melhor opção para rastreio de idosos

em risco na comunidade. Esse artigo também mostrou que a imobilidade em pessoas idosas, avaliada pela impossibilidade de executar os testes de caminhada e de levantar da cadeira, é um fator importante de risco para o óbito por todas as causas e por doenças do aparelho circulatório.

O terceiro artigo encontrou que, utilizando-se como preditores as variáveis socioeconômicas, de saúde e testes de performance física, algoritmos de *machine learning* conseguem prever com bom desempenho a mortalidade por doenças do aparelho respiratório em idosos. Esse resultado indica que esses algoritmos podem ser uma ferramenta útil no rastreio de pessoas em risco de apresentar esse desfecho, facilitando a organização de estratégias preventivas. A predição de óbito por doenças cardiovasculares e neoplasias não apresentaram desempenho similar, indicando que é provável que outras variáveis preditoras sejam necessárias para treinar os modelos. No quarto artigo, os algoritmos de *machine learning* também se mostraram promissores na identificação de idosos que apresentarão declínio da mobilidade futuro em tarefas específicas, como ajoelhar, agachar e carregar pesos.

Num contexto em que a década do envelhecimento saudável coincide com o início de uma grave pandemia no mundo, tornam-se mais urgentes ações que reduzam as lacunas existentes nas políticas públicas, sistemas e serviços de saúde. Nessa busca por soluções para um envelhecimento saudável da população, e numa realidade em que as novas tecnologias têm sido cada vez mais acessíveis, o uso de algoritmos de *machine learning* para predição de desfechos adversos em idosos pode ser um importante aliado na alocação de recursos. Reforça-se ainda a importância de medidas de equidade no acesso aos serviços, uma vez que aspectos socioeconômicos são fatores que influenciam mais diretamente no processo de envelhecimento.

REFERÊNCIAS BIBLIOGRÁFICAS

1. United Nations Department of Economic and Social Affairs/Population Division. World Population Prospects 2019. Published 2019. Accessed March 6, 2021. <https://population.un.org/wpp/Graphs/Probabilistic/PopPerc/60plus/76>
2. Beard JR, Officer A, de Carvalho IA, et al. The World report on ageing and health: a policy framework for healthy ageing. *Lancet*. 2016;387(10033):2145-2154. doi:10.1016/S0140-6736(15)00516-4
3. World Health Organization. Ageing and health. Published 2018. Accessed March 25, 2021. [https://www.who.int/news-room/fact-sheets/detail/ageing-and-health#:~:text=Today%2C for the first time,aged 80 years or older.](https://www.who.int/news-room/fact-sheets/detail/ageing-and-health#:~:text=Today%2C%20for%20the%20first%20time,aged%2080%20years%20or%20older.)
4. Prince MJ, Wu F, Guo Y, et al. The burden of disease in older people and implications for health policy and practice. *Lancet*. 2015;385(9967):549-562. doi:10.1016/S0140-6736(14)61347-7
5. Dahlgren G, Whitehead M. Policies and strategies to promote social equity in health. Background document to WHO – Strategy paper. *Intitute Futur Stud*. 2007;14:1-67. http://ideas.repec.org/p/hhs/ifswps/2007_014.html
6. Stenholm S, Westerlund H, Head J, et al. Comorbidity and Functional Trajectories From Midlife to Old Age: The Health and Retirement Study. *Journals Gerontol*. 2015;70(3):330-336. doi:10.1093/gerona/glu113
7. Kuh D, Karunananthan S, Bergman H, Cooper R. A life-course approach to healthy ageing: maintaining physical capability. *Proc Nutr Soc*. 2014;73(2):237-248. doi:10.1017/S0029665113003923

8. World Health Organization. *Decade of Healthy Ageing: Baseline Report.*; 2020.
<https://www.who.int/ageing/decade-of-healthy-ageing>
9. Rudnicka E, Napierała P, Podfigurna A, Męczekalski B, Smolarczyk R, Grymowicz M. The World Health Organization (WHO) approach to healthy ageing. *Maturitas*. 2020;139(February):6-11. doi:10.1016/j.maturitas.2020.05.018
10. Centro Colaborador da Organização Mundial da Saúde para a Família da Classificações Internacionais em Português. *Classificação Internacional de Funcionalidade, Incapacidade e Saúde*. 1st ed. (Buchalla CM, ed.). Editora da Universidade de São Paulo; 2015.
11. Shumway-Cook A, Patla AE, Stewart A, Ferrucci L, Ciol MA, Guralnik JM. Environmental Demands Associated With Community Mobility in Older Adults With and Without Mobility Disabilities. *Phys Ther*. 2002;82(7):670-681.
doi:10.1093/ptj/82.7.670
12. United Nations Department of Economic and Social Affairs/Population Division. *World Population Ageing 2015.*; 2015.
13. Wilmoth JR. Demography of longevity: past, present, and future trends. *Exp Gerontol*. 2000;35(9-10):1111-1129. doi:10.1016/S0531-5565(00)00194-7
14. Fries JF. Aging, Natural Death, and the Compression of Morbidity. *N Engl J Med*. 1980;303(3):130-135. doi:10.1056/NEJM198007173030304
15. Mathers CD, Stevens G a, Boerma T, White R a, Tobias MI. Causes of international increases in older age life expectancy. *Lancet*. 2015;385(9967):540-548.
doi:10.1016/S0140-6736(14)60569-9
16. Vasconcelos AMN, Gomes MMF. Transição demográfica: a experiência brasileira.

- Epidemiol e Serviços Saúde*. 2012;21(4):539-548. doi:10.5123/S1679-49742012000400003
17. Instituto Brasileiro de Geografia e Estatística. Censo 2010. Published 2010. Accessed January 1, 2014. <http://www.censo2010.ibge.gov.br/>
 18. Marinho F, de Azeredo Passos VM, Carvalho Malta D, et al. Burden of disease in Brazil, 1990–2016: a systematic subnational analysis for the Global Burden of Disease Study 2016. *Lancet*. 2018;392(10149):760-775. doi:10.1016/S0140-6736(18)31221-2
 19. Ministério da Saúde. Departamento de Informática do Sistema Único de Saúde (DATASUS). Published 2020. Accessed July 28, 2020. <http://www2.datasus.gov.br/DATASUS/index.php?area=0206&id=6942&VObj=http://tabnet.datasus.gov.br/cgi/defctohtm.exe?ibge/cnv/pop>
 20. Ramos LR, Veras RP, Kalache A. Envelhecimento populacional: uma realidade brasileira. *Rev Saude Publica*. 1987;21(3):211-224. doi:10.1590/S0034-89101987000300006
 21. Cieza A, Causey K, Kamenov K, Hanson SW, Chatterji S, Vos T. Global estimates of the need for rehabilitation based on the Global Burden of Disease study 2019: a systematic analysis for the Global Burden of Disease Study 2019. *Lancet*. 2020;396(10267):2006-2017. doi:10.1016/S0140-6736(20)32340-0
 22. Salive ME. Multimorbidity in Older Adults. *Epidemiol Rev*. 2013;35(1):75-83. doi:10.1093/epirev/mxs009
 23. Bernardes GM, Saulo H, Fernandez RN, Lima-Costa F, Andrade FB de. Gastos catastróficos em saúde e multimorbidade entre adultos mais velhos no Brasil. *Rev Saude Publica*. 2020;54(125):1-11. doi:10.11606/s1518-8787.2020054002285

24. Nunes BP, Soares MU, Wachs LS, et al. Hospitalization in older adults: association with multimorbidity, primary health care and private health plan. *Rev Saude Publica*. 2017;51:1-10. doi:10.1590/s1518-8787.2017051006646
25. do Nascimento CF, Duarte YAO, Lebrão ML, Chiavegatto Filho ADP. Individual and Neighborhood Factors Associated With Functional Mobility and Falls in Elderly Residents of São Paulo, Brazil: A Multilevel Analysis. *J Aging Health*. 2018;30(1):118-139. doi:10.1177/0898264316669229
26. Quiñones AR, Markwardt S, Botosaneanu A. Multimorbidity Combinations and Disability in Older Adults. *Journals Gerontol Ser A Biol Sci Med Sci*. 2016;71(6):823-830. doi:10.1093/gerona/glw035
27. Roman Lay AA, Ferreira do Nascimento C, Caba Burgos F, et al. Gender Differences between Multimorbidity and All-Cause Mortality among Older Adults. *Curr Gerontol Geriatr Res*. 2020;2020:1-7. doi:10.1155/2020/7816785
28. Andrasfay T, Goldman N. Reductions in 2020 US life expectancy due to COVID-19 and the disproportionate impact on the Black and Latino populations. *Proc Natl Acad Sci*. 2021;118(5):e2014746118. doi:10.1073/pnas.2014746118
29. Marois G, Muttarak R, Scherbov S. Assessing the potential impact of COVID-19 on life expectancy. Masquelier B, ed. *PLoS One*. 2020;15(9):e0238678. doi:10.1371/journal.pone.0238678
30. Aburto JM, Kashyap R, Schöley J, et al. Estimating the burden of the COVID-19 pandemic on mortality, life expectancy and lifespan inequality in England and Wales: a population-level analysis. *J Epidemiol Community Health*. Published online January 19, 2021;jech-2020-215505. doi:10.1136/jech-2020-215505

31. United Nations Department of Economic and Social Affairs/Population Division.
World Population Ageing 2020 Highlights: Living Arrangements of Older Persons.; 2020.
32. Shahid Z, Kalayanamitra R, McClafferty B, et al. COVID-19 and Older Adults: What We Know. *J Am Geriatr Soc.* 2020;68(5):926-929. doi:10.1111/jgs.16472
33. Sharma A. Estimating Older Adult Mortality From COVID-19. Carr DS, ed. *Journals Gerontol Ser B.* 2021;76(3):e68-e74. doi:10.1093/geronb/gbaa161
34. World Health Organization. *Global Report on Urban Health: Equitable, Healthier Cities for Sustainable Development.* Vol 1.; 2016.
35. Oliven RG. *Urbanização e Mudança Social No Brasil.* (Edelstein C, ed.). Centro Edelstein; 2010. doi:10.7476/9788579820014
36. Global Agenda Council on Ageing Society. *Global Population Ageing : Peril or Promise ?* (World Economic Forum, ed.); 2012.
37. Glass TA, Balfour JL. Neighborhood, Aging and Functional Limitations. In: Kawachi I, Berkman LF, eds. *Neighborhoods and Health.* Oxford University Press; 2003:303-334.
38. World Health Organization. *Global Age-Friendly Cities: A Guide.* World Health Organization; 2007.
39. Plouffe L, Kalache A. Towards Global Age-Friendly Cities: Determining Urban Features that Promote Active Aging. *J Urban Heal.* 2010;87(5):733-739. doi:10.1007/s11524-010-9466-0
40. World Health Organisation. *The Global Network for Age-Friendly Cities and Communities: Looking Back over the Last Decade, Looking Forward to the Next.*; 2018.

- <https://apps.who.int/iris/bitstream/handle/10665/278979/WHO-FWC-ALC-18.4-eng.pdf?sequence=1>
41. Gawryszewski VP, Costa LS. Homicídios e desigualdades sociais no Município de São Paulo. *Rev Saude Publica*. 2005;39(2):191-197.
 42. Albala C, Lebrão ML, Díaz EML, et al. Encuesta Salud , Bienestar y Envejecimiento (SABE): metodología de la encuesta y perfil de la población estudiada. *Rev Panam Salud Publica*. 2005;17(5/6):307-322.
 43. Lebrão ML, Duarte YA de O, Santos JLF, Silva NN da. 10 Years of SABE Study: background, methodology and organization of the study. *Rev Bras Epidemiol*. 2018;21(suppl 2). doi:10.1590/1980-549720180002.supl.2
 44. Lebrão ML, Duarte YA de O. Desafios de um estudo longitudinal : o Projeto SABE. *Saúde Coletiva*. 2008;5(24):166-167.
 45. Duim E, Lima Passos V. Highways to Ageing - Linking life course SEP to multivariate trajectories of health outcomes in older adults. *Arch Gerontol Geriatr*. 2020;91(July):104193. doi:10.1016/j.archger.2020.104193
 46. Kuh D. Life course epidemiology. *J Epidemiol Community Heal*. 2003;57(10):778-783. doi:10.1136/jech.57.10.778
 47. Organização Mundial da Saúde. Relatório Mundial de Envelhecimento e Saúde. *Relatório Mund Envelhec e Saúde*. Published online 2015. doi:10.1007/s13398-014-0173-7.2
 48. Perracini MR, Guerra RO, Pereira DS. Funcionalidade e Envelhecimento. In: Perracini MR, Fló CM, eds. *Funcionalidade e Envelhecimento*. 2nd ed. Guanabara Koogan; 2019.

49. Steves CJ, Spector TD, Jackson SHD. Ageing, genes, environment and epigenetics: what twin studies tell us now, and in the future. *Age Ageing*. 2012;41(5):581-586. doi:10.1093/ageing/afs097
50. Lourenço RA, Moreira VG, Mello RGB de, et al. Consenso brasileiro de fragilidade em idosos: conceitos, epidemiologia e instrumentos de avaliação. *Geriatr Gerontol Aging*. 2018;12(2):121-135. doi:10.5327/Z2447-211520181800023
51. Clegg A, Young J, Iliffe S, Rikkert MO, Rockwood K. Frailty in elderly people. *Lancet*. 2013;381(9868):752-762. doi:10.1016/S0140-6736(12)62167-9
52. Melo RC, Cipolli GC, Buarque GLA, et al. Prevalence of Frailty in Brazilian Older Adults: A Systematic Review and Meta-Analysis. *J Nutr Health Aging*. 2020;24(7):708-716. doi:10.1007/s12603-020-1398-0
53. Andrade JM, Duarte YA de O, Alves LC, et al. Frailty profile in Brazilian older adults. *Rev Saude Publica*. 2019;52(Suppl 2):17s. doi:10.11606/s1518-8787.2018052000616
54. Fried LP, Tangen CM, Walston J, et al. Frailty in Older Adults: Evidence for a Phenotype. *Journals Gerontol Ser A Biol Sci Med Sci*. 2001;56(3):M146-M157. doi:10.1093/gerona/56.3.M146
55. Katz S, Downs TD, Cash HR, Grotz RC. Progress in Development of the Index of ADL. *Gerontologist*. 1970;10(1 Part 1):20-30. doi:10.1093/geront/10.1_Part_1.20
56. Lawton MP, Brody EM. Assessment of Older People: Self-Maintaining and Instrumental Activities of Daily Living. *Gerontologist*. 1969;9(3 Part 1):179-186. doi:10.1093/geront/9.3_Part_1.179
57. Santos JLF, Lebrão ML, Duarte YAO, Lima FD De. Functional performance of the elderly in instrumental activities of daily living: an analysis in the municipality of São

- Paulo, Brazil. *Cad Saude Publica*. 2008;24(4):879-886. doi:10.1590/S0102-311X2008000400019
58. Alexandre TDS, Corona LP, Nunes DP, Santos JLF, Duarte YADO, Lebrão ML. Disability in instrumental activities of daily living among older adults: gender differences. *Rev Saude Publica*. 2014;48(3):379-389. doi:10.1590/S0034-8910.2014048004754
 59. Alexandre T da S, Corona LP, Nunes DP, Santos JLF, Duarte YA de O, Lebrão ML. Gender differences in incidence and determinants of disability in activities of daily living among elderly individuals: SABE study. *Arch Gerontol Geriatr*. 2012;55(2):431-437. doi:10.1016/j.archger.2012.04.001
 60. Patla A, Shumway-cook A. Dimensions of mobility: Defining the complexity and difficulty associated with community mobility. *J Aging Phys Act*. 1999;7(1):7-19. doi:10.1177/053901847201100504
 61. Satariano WA, Guralnik JM, Jackson RJ, Marottoli RA, Phelan EA, Prohaska TR. Mobility and Aging: New Directions for Public Health Action. *Am J Public Health*. 2012;102(8):1508-1515. doi:10.2105/AJPH.2011.300631
 62. Freedman VA, Carr D, Cornman JC, Lucas RE. Aging, mobility impairments and subjective wellbeing. *Disabil Health J*. 2017;10(4):525-531. doi:10.1016/j.dhjo.2017.03.011
 63. Rantakokko M, Portegijs E, Viljanen A, Iwarsson S, Rantanen T. Life-Space Mobility and Quality of Life in Community-Dwelling Older People. *J Am Geriatr Soc*. 2013;61(10):1830-1832. doi:10.1111/jgs.12473
 64. Ferrucci L, Cooper R, Shardell M, Simonsick EM, Schrack JA, Kuh D. Age-Related

- Change in Mobility: Perspectives From Life Course Epidemiology and Geroscience. *Journals Gerontol Ser A Biol Sci Med Sci*. 2016;71(9):1184-1194.
doi:10.1093/gerona/glw043
65. Rantakokko M, Mänty M, Rantanen T. Mobility Decline in Old Age. *Exerc Sport Sci Rev*. 2013;41(1):19-25. doi:10.1097/JES.0b013e3182556f1e
 66. Shumway-cook A, Woollacott M. *Controle Motor: Teoria e Aplicações Práticas*. 3rd ed. Manole; 2010.
 67. Ferrer MLP, Ferreira LTD. Mobilidade no Idoso. In: Perracini MR, Fló CM, eds. *Funcionalidade e Envelhecimento*. 2nd ed. Guanabara Koogan; 2019.
 68. Baloh RW, Ying SH, Jacobson KM. A Longitudinal Study of Gait and Balance Dysfunction in Normal Older People. *Arch Neurol*. 2003;60(6):835.
doi:10.1001/archneur.60.6.835
 69. Sorond FA, Cruz-Almeida Y, Clark DJ, et al. Aging, the Central Nervous System, and Mobility in Older Adults: Neural Mechanisms of Mobility Impairment. *Journals Gerontol Ser A Biol Sci Med Sci*. 2015;70(12):1526-1532. doi:10.1093/gerona/glv130
 70. Tournadre A, Vial G, Capel F, Soubrier M, Boirie Y. Sarcopenia. *Jt Bone Spine*. 2019;86(3):309-314. doi:10.1016/j.jbspin.2018.08.001
 71. Cruz-Jentoft AJ, Bahat G, Bauer J, et al. Sarcopenia: revised European consensus on definition and diagnosis. *Age Ageing*. 2019;48(1):16-31. doi:10.1093/ageing/afy169
 72. Morley JE, Abbatecola AM, Argiles JM, et al. Sarcopenia With Limited Mobility: An International Consensus. *J Am Med Dir Assoc*. 2011;12(6):403-409.
doi:10.1016/j.jamda.2011.04.014
 73. Beaudart C, Zaaria M, Pasleau F, Reginster J-Y, Bruyère O. Health Outcomes of

- Sarcopenia: A Systematic Review and Meta-Analysis. Wright JM, ed. *PLoS One*. 2017;12(1):e0169548. doi:10.1371/journal.pone.0169548
74. Rantanen T, Guralnik JM, Ferrucci L, Leveille S, Fried LP. Coimpairments: Strength and Balance as Predictors of Severe Walking Disability. *Journals Gerontol Ser A Biol Sci Med Sci*. 1999;54(4):M172-M176. doi:10.1093/gerona/54.4.M172
 75. Stenholm S, Shardell M, Bandinelli S, Guralnik JM, Ferrucci L. Physiological Factors Contributing to Mobility Loss Over 9 Years of Follow-Up—Results From the InCHIANTI Study. *Journals Gerontol Ser A Biol Sci Med Sci*. 2015;70(5):591-597. doi:10.1093/gerona/glv004
 76. Huang C, Sun S, Wang W, Li Y, Feng W, Wu Y. Cognition Mediates the Relationship Between Sensory Function and Gait Speed in Older Adults: Evidence from the English Longitudinal Study of Ageing. Montero-Odasso M, ed. *J Alzheimer's Dis*. 2019;70(4):1153-1161. doi:10.3233/JAD-190364
 77. Yang F, Hassani A, Brost V, Mourey F, Kubicki A. Kinematic analysis of motor strategies in frail aged adults during the Timed Up and Go: how to spot the motor frailty? *Clin Interv Aging*. 2015;10:505. doi:10.2147/CIA.S74755
 78. Perera S, Patel K V., Rosano C, et al. Gait Speed Predicts Incident Disability: A Pooled Analysis. *Journals Gerontol Ser A Biol Sci Med Sci*. 2016;71(1):63-71. doi:10.1093/gerona/glv126
 79. Jung H-W, Jang I-Y, Lee CK, et al. Usual gait speed is associated with frailty status, institutionalization, and mortality in community-dwelling rural older adults: a longitudinal analysis of the Aging Study of Pyeongchang Rural Area. *Clin Interv Aging*. 2018;Volume 13:1079-1089. doi:10.2147/CIA.S166863

80. Cummings SR, Studenski S, Ferrucci L. A Diagnosis of Dismobility—Giving Mobility Clinical Visibility. *JAMA*. 2014;311(20):2061. doi:10.1001/jama.2014.3033
81. Fritz S, Lusardi M. White Paper: “Walking Speed: the Sixth Vital Sign.” *J Geriatr Phys Ther*. 2009;32(2):2-5. doi:10.1519/00139143-200932020-00002
82. Middleton A, Fritz SL, Lusardi M. Walking Speed: The Functional Vital Sign. *J Aging Phys Act*. 2015;23(2):314-322. doi:10.1123/japa.2013-0236
83. Rydwick E, Bergland A, Forsén L, Frändin K. Investigation into the reliability and validity of the measurement of elderly people’s clinical walking speed: A systematic review. *Physiother Theory Pract*. 2012;28(3):238-256.
doi:10.3109/09593985.2011.601804
84. Peters DM, Fritz SL, Krotish DE. Assessing the Reliability and Validity of a Shorter Walk Test Compared With the 10-Meter Walk Test for Measurements of Gait Speed in Healthy, Older Adults. *J Geriatr Phys Ther*. 2013;36(1):24-30.
doi:10.1519/JPT.0b013e318248e20d
85. Viccaro LJ, Perera S, Studenski SA. Is Timed Up and Go Better Than Gait Speed in Predicting Health, Function, and Falls in Older Adults? *J Am Geriatr Soc*. 2011;59(5):887-892. doi:10.1111/j.1532-5415.2011.03336.x
86. White DK, Neogi T, Nevitt MC, et al. Trajectories of Gait Speed Predict Mortality in Well-Functioning Older Adults: The Health, Aging and Body Composition Study. *Journals Gerontol Ser A Biol Sci Med Sci*. 2013;68(4):456-464.
doi:10.1093/gerona/gls197
87. Studenski S, Perera S, Patel K, et al. Gait Speed and Survival in Older Adults. *JAMA*. 2011;305(1):50. doi:10.1001/jama.2010.1923

88. Busch TDA, Duarte YA, Pires Nunes D, et al. Factors associated with lower gait speed among the elderly living in a developing country: a cross-sectional population-based study. *BMC Geriatr.* 2015;15(1):35. doi:10.1186/s12877-015-0031-2
89. Duim E, Lebrão ML, Antunes JLF. Walking speed of older people and pedestrian crossing time. *J Transp Heal.* 2017;5(February):70-76. doi:10.1016/j.jth.2017.02.001
90. Kerr K, White J, Barr D, Mollan R. Analysis of the sit-stand-sit movement cycle in normal subjects. *Clin Biomech.* 1997;12(4):236-245. doi:10.1016/S0268-0033(96)00077-0
91. Millington PJ, Myklebust BM, Shambes GM. Biomechanical analysis of the sit-to-stand motion in elderly persons. *Arch Phys Med Rehabil.* 1992;73(7):609-617. doi:10.5555/uri:pii:000399939290124F
92. Lord SR, Murray SM, Chapman K, Munro B, Tiedemann A. Sit-to-Stand Performance Depends on Sensation, Speed, Balance, and Psychological Status in Addition to Strength in Older People. *Journals Gerontol Ser A Biol Sci Med Sci.* 2002;57(8):M539-M543. doi:10.1093/gerona/57.8.M539
93. Zhang F, Ferrucci L, Culham E, Metter EJ, Guralnik J, Deshpande N. Performance on Five Times Sit-to-Stand Task as a Predictor of Subsequent Falls and Disability in Older Persons. *J Aging Health.* 2013;25(3):478-492. doi:10.1177/0898264313475813
94. Santos KT, Fernandes MH, Carneiro JA, da Silva Coqueiro R. Motor performance tests as screening instruments for frailty in the older adults. *Appl Nurs Res.* 2016;32:80-84. doi:10.1016/j.apnr.2016.06.003
95. Deshpande N, Metter EJ, Guralnik J, Bandinelli S, Ferrucci L. Predicting 3-Year Incident Mobility Disability in Middle-Aged and Older Adults Using Physical

- Performance Tests. *Arch Phys Med Rehabil*. 2013;94(5):994-997.
doi:10.1016/j.apmr.2012.10.032
96. Podsiadlo D, Richardson S. The timed “Up & Go”: a test of basic functional mobility for frail elderly persons. *J Am Geriatr Soc*. 1991;39(2):142-148. Accessed October 28, 2014. <http://www.ncbi.nlm.nih.gov/pubmed/1991946>
 97. Alexandre TS, Meira DM, Rico NC, Mizuta SK. Accuracy of Timed Up and Go Test for screening risk of falls among community-dwelling elderly. *Rev Bras Fisioter*. 2012;16(5):381-388. doi:10.1590/S1413-35552012005000041
 98. do Nascimento CF, Duarte YAO, Lebrão ML, Chiavegatto Filho ADP. Individual and contextual characteristics of indoor and outdoor falls in older residents of São Paulo, Brazil. *Arch Gerontol Geriatr*. 2017;68:119-125. doi:10.1016/j.archger.2016.10.004
 99. Guralnik JM, Simonsick EM, Ferrucci L, et al. A Short Physical Performance Battery Assessing Lower Extremity Function: Association With Self-Reported Disability and Prediction of Mortality and Nursing Home Admission. *J Gerontol*. 1994;49(2):M85-M94. doi:10.1093/geronj/49.2.M85
 100. Veronese N, Stubbs B, Fontana L, et al. A Comparison of Objective Physical Performance Tests and Future Mortality in the Elderly People. *Journals Gerontol Ser A Biol Sci Med Sci*. 2016;72(3):glw139. doi:10.1093/gerona/glw139
 101. Freire AN, Guerra RO, Alvarado B, Guralnik JM, Zunzunegui M V. Validity and Reliability of the Short Physical Performance Battery in Two Diverse Older Adult Populations in Quebec and Brazil. *J Aging Health*. 2012;24(5):863-878.
doi:10.1177/0898264312438551
 102. Tinetti ME. Performance-Oriented Assessment of Mobility Problems in Elderly

- Patients. *J Am Geriatr Soc.* 1986;34(2):119-126. doi:10.1111/j.1532-5415.1986.tb05480.x
103. Berg KO, Wood-Dauphinee SL, Williams JI, Maki B. Measuring balance in the elderly: Validation of an instrument. *Can J Public Heal.* 1992;83(SUPPL. 2).
 104. Goldman N, Gleib DA, Weinstein M. What Matters Most for Predicting Survival? A Multinational Population-Based Cohort Study. Gorlova OY, ed. *PLoS One.* 2016;11(7):e0159273. doi:10.1371/journal.pone.0159273
 105. Swindell WR, Ensrud KE, Cawthon PM, Cauley JA, Cummings SR, Miller RA. Indicators of “Healthy Aging” in older women (65-69 years of age). A data-mining approach based on prediction of long-term survival. *BMC Geriatr.* 2010;10(1):55. doi:10.1186/1471-2318-10-55
 106. Cornman JC, Gleib DA, Weinstein M. Change in Mobility: Consistency of Estimates and Predictors Across Studies of Older Adults. Kelley J, ed. *Journals Gerontol Ser B.* 2021;76(1):209-218. doi:10.1093/geronb/gbz091
 107. Parahyba MI, Simões CC da S. A prevalência de incapacidade funcional em idosos no Brasil. *Cien Saude Colet.* 2006;11(4):967-974. doi:10.1590/S1413-81232006000400018
 108. Bendayan R, Cooper R, Wloch EG, Hofer SM, Piccinin AM, Muniz-Terrera G. Hierarchy and Speed of Loss in Physical Functioning: A Comparison Across Older U.S. and English Men and Women. *Journals Gerontol Ser A Biol Sci Med Sci.* 2016;72(8):glw209. doi:10.1093/gerona/glw209
 109. Seidel D, Brayne C, Jagger C. Limitations in physical functioning among older people as a predictor of subsequent disability in instrumental activities of daily living. *Age*

- Ageing*. 2011;40(4):463-469. doi:10.1093/ageing/afr054
110. Melzer D, Parahyba MI. Socio-demographic correlates of mobility disability in older Brazilians: results of the first national survey. *Age Ageing*. 2004;33(3):253-259. doi:10.1093/ageing/afh075
 111. Latham K. Racial and Educational Disparities in Mobility Limitation Among Older Women: What Is the Role of Modifiable Risk Factors? *Journals Gerontol Ser B Psychol Sci Soc Sci*. 2014;69(5):772-783. doi:10.1093/geronb/gbu028
 112. Latham K, Clarke PJ, Pavea G. Social Relationships, Gender, and Recovery From Mobility Limitation Among Older Americans. *Journals Gerontol Ser B Psychol Sci Soc Sci*. 2015;70(5):769-781. doi:10.1093/geronb/gbu181
 113. Jacob ME, Marron MM, Boudreau RM, Odden MC, Arnold AM, Newman AB. Age, Race, and Gender Factors in Incident Disability. *Journals Gerontol Ser A*. 2018;73(2):194-197. doi:10.1093/gerona/glx194
 114. Dellaroza MSG, Pimenta CA de M, Duarte YA, Lebrão ML. Dor crônica em idosos residentes em São Paulo, Brasil: prevalência, características e associação com capacidade funcional e mobilidade (Estudo SABE). *Cad Saude Publica*. 2013;29(2):325-334.
 115. Peel C, Baker PS, Roth DL, Brown CJ, Bodner E V., Allman RM. Assessing Mobility in Older Adults: The UAB Study of Aging Life-Space Assessment. *Phys Ther*. 2005;85(10):1008-1019. doi:10.1093/ptj/85.10.1008
 116. Baker PS, Bodner E V., Allman RM. Measuring Life-Space Mobility in Community-Dwelling Older Adults. *J Am Geriatr Soc*. 2003;51(11):1610-1614. doi:10.1046/j.1532-5415.2003.51512.x

117. Perracini MR, de Amorim JSC, Lima CA, et al. Impact of COVID-19 Pandemic on Life-Space Mobility of Older Adults Living in Brazil: REMOBILIZE Study. *Front Public Heal.* 2021;9(April). doi:10.3389/fpubh.2021.643640
118. Ganna A, Ingelsson E. 5 year mortality predictors in 498 103 UK Biobank participants: a prospective population-based study. *Lancet.* 2015;386(9993):533-540. doi:10.1016/S0140-6736(15)60175-1
119. Yates T, Zaccardi F, Dhalwani NN, et al. Association of walking pace and handgrip strength with all-cause, cardiovascular, and cancer mortality: a UK Biobank observational study. *Eur Heart J.* 2017;38(43):3232-3240. doi:10.1093/eurheartj/ehx449
120. Argyridou S, Zaccardi F, Davies MJ, Khunti K, Yates T. Walking pace improves all-cause and cardiovascular mortality risk prediction: A UK Biobank prognostic study. *Eur J Prev Cardiol.* 2020;27(10):1036-1044. doi:10.1177/2047487319887281
121. Nofuji Y, Shinkai S, Taniguchi Y, et al. Associations of Walking Speed, Grip Strength, and Standing Balance With Total and Cause-Specific Mortality in a General Population of Japanese Elders. *J Am Med Dir Assoc.* 2016;17(2):184.e1-184.e7. doi:10.1016/j.jamda.2015.11.003
122. Toots A, Rosendahl E, Lundin-Olsson L, Nordström P, Gustafson Y, Littbrand H. Usual Gait Speed Independently Predicts Mortality in Very Old People: A Population-Based Study. *J Am Med Dir Assoc.* 2013;14(7):529.e1-529.e6. doi:10.1016/j.jamda.2013.04.006
123. Liu B, Hu X, Zhang Q, et al. Usual walking speed and all-cause mortality risk in older people: A systematic review and meta-analysis. *Gait Posture.* 2016;44:172-177.

doi:10.1016/j.gaitpost.2015.12.008

124. Veronese N, Stubbs B, Volpato S, et al. Association Between Gait Speed With Mortality, Cardiovascular Disease and Cancer: A Systematic Review and Meta-analysis of Prospective Cohort Studies. *J Am Med Dir Assoc.* 2018;19(11):981-988.e7. doi:10.1016/j.jamda.2018.06.007
125. Abe T, Kitamura A, Taniguchi Y, et al. Pathway from gait speed to incidence of disability and mortality in older adults: A mediating role of physical activity. *Maturitas.* 2019;123(February):32-36. doi:10.1016/j.maturitas.2019.02.002
126. Bergland A, Jørgensen L, Emaus N, Strand BH. Mobility as a predictor of all-cause mortality in older men and women: 11.8 year follow-up in the Tromsø study. *BMC Health Serv Res.* 2017;17(1):22. doi:10.1186/s12913-016-1950-0
127. Panas LJ, Siordia C, Angel RJ, Eschbach K, Markides KS. Physical Performance and Short-Term Mortality in Very Old Mexican Americans. *Exp Aging Res.* 2013;39(5):481-492. doi:10.1080/0361073X.2013.839021
128. Pavaasini R, Guralnik J, Brown JC, et al. Short Physical Performance Battery and all-cause mortality: systematic review and meta-analysis. *BMC Med.* 2016;14(1):215. doi:10.1186/s12916-016-0763-7
129. Olaya B, Moneta MV, Doménech-Abella J, et al. Mobility Difficulties, Physical Activity, and All-cause Mortality Risk in a Nationally representative Sample of Older Adults. *Journals Gerontol Ser A.* 2018;73(9):1272-1279. doi:10.1093/gerona/glx121
130. Nascimento C de M, Oliveira C de, Firmo JOA, Lima-Costa MF, Peixoto SV. Prognostic value of disability on mortality: 15-year follow-up of the Bambuí cohort study of aging. *Arch Gerontol Geriatr.* 2018;74(October 2017):112-117.

doi:10.1016/j.archger.2017.10.011

131. Suemoto CK, Ueda P, Beltrán-Sánchez H, et al. Development and Validation of a 10-Year Mortality Prediction Model: Meta-Analysis of Individual Participant Data From Five Cohorts of Older Adults in Developed and Developing Countries. *J Gerontol A Biol Sci Med Sci*. 2016;00(00):1-7. doi:10.1093/gerona/glw166
132. Bachettini NP, Bielemann RM, Barbosa-Silva TG, Menezes AMB, Tomasi E, Gonzalez MC. Sarcopenia as a mortality predictor in community-dwelling older adults: a comparison of the diagnostic criteria of the European Working Group on Sarcopenia in Older People. *Eur J Clin Nutr*. 2020;74(4):573-580. doi:10.1038/s41430-019-0508-8
133. Lebrão ML, Duarte YA de O. *O Projeto SABE No Município de São Paulo: Uma Abordagem Inicial*. 1st ed. Organização Pan-Americana de Saúde; 2003.
134. Géron A. *Mãos à Obra : Aprendizado de Máquina Com Scikit-Learn & TensorFlow*. Alta Books; 2019.
135. Batista AF de M, Chiavegatto Filho ADP. Machine Learning aplicado à Saúde. In: Fernandes NC, Ziviani A, Saade DCM, eds. *Minicursos Do Simpósio Brasileiro de Computação Aplicada à Saúde 2019*. 19th ed. Sociedade Brasileira de Computação; 2019. <https://sol.sbc.org.br/livros/index.php/sbc/catalog/book/29>
136. Chawla N V, Bowyer KW, Hall LO, Kegelmeyer WP. SMOTE : Synthetic Minority Over-sampling Technique. *J Artif Intell Res*. 2002;16:321-357. doi:10.1613/jair.953
137. Raschka S. *Python Machine Learning*. Packt Publishing Ltd. Livery; 2015.
138. Lundberg SM, Lee S-I. A Unified Approach to Interpreting Model Predictions. *Adv Neural Inf Process Syst*. Published online 2017:4765–4774.
139. PyCaret.org. PyCaret. PyCaret version 1.0.0. Published 2020. Accessed February 9,

2020. <https://pycaret.org/about>

APÊNDICE I

A tabela abaixo complementa os resultados do artigo 4, e apresenta algumas métricas de desempenho de algoritmos de *machine learning* na predição de dificuldade em cada uma das 4 tarefas de mobilidade num intervalo de cinco anos. Para esses resultados foram considerados na linha de base apenas os indivíduos que não apresentavam queixa em nenhuma das 4 tarefas. Nela estão apresentados os resultados dos algoritmos com melhor performance em cada predição.

Performance dos melhores algoritmos na predição de dificuldade em tarefas de mobilidade numa amostra de indivíduos sem limitação em nenhuma das 4 tarefas.

Tarefa	Algoritmo com melhor performance	AUC-ROC	Sensibilidade	Especificidade
Dificuldade para caminhar	Catboost	0,69	0,17	0,94
Dificuldade para subir escadas	Extra trees classifier	0,74	0,04	0,96
Dificuldade para agachar	Catboost	0,65	0,38	0,82
Dificuldade para carregar pesos	Light Gradient Boosting Machine	0,69	0,36	0,89

ANEXO I

UNIVERSIDADE DE SÃO PAULO
FACULDADE DE SAÚDE PÚBLICA
COMITÊ DE ÉTICA EM PESQUISA DA FSP/USP - COEP
Av. Dr. Arnaldo, 715 - CEP 01246-904 - São Paulo - Brasil
Telefones: (55-11) 3066 7742 - fax (55-11) 3064 7314

Of.COEP/67/99

24 de maio de 1999

Pelo presente, informo que o Comitê de Ética em Pesquisa, **aprovou**, em sua 3.ª/99, Sessão Ordinária, de 19.05.99, de acordo com os requisitos da Resolução CNS/196/96, o Projeto de Pesquisa "AS CONDIÇÕES DE SAÚDE DOS IDOSOS NA AMÉRICA DO SUL E CARIBE", apresentado pelo pesquisador Ruy Laurenti, devendo ser remetido à CONEP conforme as normas da Resolução 196/96.

Atenciosamente,

Prof. Dr. Paulo Antonio de Carvalho Fortes
Vice-Coordenador do Comitê de Ética em Pesquisa da FSP-COEP

Universidade de São Paulo
Faculdade de Saúde Pública

COMITÊ DE ÉTICA - COEP

Av. Dr. Arnaldo, 715 – Assessoria Acadêmica - CEP 01246-904 – São Paulo – Brasil
Telefones: (55-11) 3066-7779 – e-mail: coep@fsp.usp.br

Of.COEP/83/06

14 de março de 2006

Pelo presente, informo que o Comitê de Ética em Pesquisa da Faculdade de Saúde Pública da Universidade de São Paulo-COEP, **aprovou** o Protocolo de Pesquisa n.º 1345, intitulado: "PROJETO SABE-2005 – SAÚDE, BEM-ESTAR E ENVELHECIMENTO. AS CONDIÇÕES DE SAÚDE E DE VIDA DOS IDOSOS NO MUNICÍPIO DE SÃO PAULO", apresentado pela pesquisadora Maria Lúcia Lebrão.

Atenciosamente,

Helena Akemi Wada Watanabe
Professora Doutora

Vice-Coordenadora do Comitê de Ética em Pesquisa da FSP-COEP

COMITÊ DE ÉTICA EM PESQUISA – COEP/FSP

Universidade de São Paulo
Faculdade de Saúde Pública

OF.COEP/23/10

5 de março de 2010.

Prezado(a) Pesquisador(a) e Orientador(a),

O Comitê de Ética em Pesquisa da Faculdade de Saúde Pública da Universidade de São Paulo – COEP/FSP, **analisou**, de acordo com a Resolução N.º 196/96 do Conselho Nacional de Saúde – CNS e suas complementares, o protocolo de pesquisa n.º **2044**, intitulado **"ESTUDO SABE 2010: SAÚDE, BEM-ESTAR E ENVELHECIMENTO - ESTUDO LONGITUDINAL SOBRE AS CONDIÇÕES DE VIDA E SAÚDE DOS IDOSOS NO MUNICÍPIO DE SÃO PAULO"**, área temática **GRUPO III**, sob responsabilidade do(a) pesquisador(a) **Maria Lucia Lebrão**, e considerou que a pendência anteriormente apresentada por este COEP foi atendida. Protocolo de pesquisa **APROVADO "AD-REFERENDUM"**.

Cabe lembrar que conforme Resolução CN /196/96, são deveres do (a) pesquisador (a): **1. Comunicar**, de imediato, qualquer alteração no projeto e aguardar manifestação deste CEP (Comitê de Ética em Pesquisa), para dar continuidade à pesquisa; **2. Manter sob sua guarda e em local seguro**, pelo prazo de 5 (cinco) anos, os dados da pesquisa, contendo fichas individuais e todos os demais documentos recomendados pelo CEP, no caso eventual auditoria; **3. Comunicar**, formalmente a este Comitê, quando do encerramento deste projeto; **4. Elaborar e apresentar relatórios parciais e final**; **5. Justificar**, perante o CEP, interrupção do projeto ou a não publicação dos resultados.

Atenciosamente,

Cláudio Leone
Professor Titular

Coordenador do Comitê de Ética em Pesquisa - COEP

Ilm.ª Sr.ª

Prof.ª Tit. Maria Lucia Lebrão
Departamento de Epidemiologia da FSP/USP

USP - FACULDADE DE SAÚDE
PÚBLICA DA UNIVERSIDADE
DE SÃO PAULO - FSP/USP

PARECER CONSUBSTANCIADO DO CEP

DADOS DO PROJETO DE PESQUISA

Título da Pesquisa: ESTUDO SABE - SAÚDE, BEM-ESTAR E ENVELHECIMENTO - Coorte 2015

Estudo longitudinal de múltiplas coortes sobre as condições de vida e saúde dos idosos no Município de São Paulo.

Pesquisador: YEDA APARECIDA DE OLIVEIRA DUARTE

Área Temática:

Versão: 2

CAAE: 47683115.4.0000.5421

Instituição Proponente: Faculdade de Saúde Pública da Universidade de São Paulo - FSP/USP

Patrocinador Principal: FUNDAÇÃO DE AMPARO A PESQUISA DO ESTADO DE SÃO PAULO

DADOS DO PARECER

Número do Parecer: 3.600.782

Apresentação do Projeto:

Trata-se de projeto temático sobre saúde do idoso, com base em amostra representativa e seguimento longitudinal (4a onda) de residentes na cidade de São Paulo.

Objetivo da Pesquisa:

Descrever e analisar padrões de vida e de saúde de idosos na cidade de São Paulo, bem como de seus determinantes e fatores associados.

Avaliação dos Riscos e Benefícios:

O projeto equacionou adequadamente a avaliação de riscos e benefícios. Já foi aprovado para as ondas anteriores e já havia sido aprovado quanto a esse quesito para a corrente avaliação da 4a onda do seguimento longitudinal.

Comentários e Considerações sobre a Pesquisa:

A única pendência levantada dizia respeito à solicitação de informações adicionais quanto ao envio ao exterior de amostras de sangue para a realização de exames genéticos de interesse para o estudo.

Considerações sobre os Termos de apresentação obrigatória:

Foram apresentados os termos obrigatórios. O TCLE informa adequadamente aos participantes do

Endereço: Av. Doutor Arnaldo, 715

Bairro: Cerqueira Cesar

CEP: 01.246-904

UF: SP

Município: SÃO PAULO

Telefone: (11)3061-7779

Fax: (11)3061-7779

E-mail: coep@fsp.usp.br

USP - FACULDADE DE SAÚDE
PÚBLICA DA UNIVERSIDADE
DE SÃO PAULO - FSP/USP

Continuação do Parecer: 3.600.782

estudo de que sua amostra de sangue poderá ser levada ao exterior para a realização de exames genéticos de interesse para o estudo.

Conclusões ou Pendências e Lista de Inadequações:

Considero que os esclarecimentos adicionais prestados pela proponente são suficientes e recomendo aprovação do presente projeto.

Considerações Finais a critério do CEP:

Este parecer foi elaborado baseado nos documentos abaixo relacionados:

Tipo Documento	Arquivo	Postagem	Autor	Situação
Informações Básicas do Projeto	PB_INFORMAÇÕES_BASICAS_DO_PROJETO_518377.pdf	24/07/2019 16:52:18		Aceito
Outros	Resposta_pendencia_Yeda.docx	24/07/2019 16:51:38	YEDA APARECIDA DE OLIVEIRA DUARTE	Aceito
Declaração de concordância	Justificativasabe.pdf	14/02/2017 17:23:46	Márcia Ferreira dos Santos	Aceito
Solicitação registrada pelo CEP	Deacordosabe.pdf	14/02/2017 17:23:46	Márcia Ferreira dos Santos	Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	TCLE03092015.pdf	03/09/2015 12:27:45	MARIA LUCIA LEBRÃO	Aceito
Folha de Rosto	pagina rosto Coep SABE 15.pdf	15/06/2015 13:09:04		Aceito
Projeto Detalhado / Brochura Investigador	Projeto SABE 2015.pdf	08/06/2015 21:09:45		Aceito

Situação do Parecer:

Aprovado

Necessita Apreciação da CONEP:

Não

Endereço: Av. Doutor Arnaldo, 715

Bairro: Cerqueira Cesar

CEP: 01.245-904

UF: SP

Município: SÃO PAULO

Telefone: (11)3061-7779

Fax: (11)3061-7779

E-mail: coep@fsp.usp.br

ANEXO II

08/07/2021

Gmail - Submission Confirmation

Carla Ferreira do Nascimento <nascimento.cfd@gmail.com>

Submission Confirmation

1 message

Aging Clinical and Experimental Research (ACER) <em@editorialmanager.com> Sat, Jun 12, 2021 at 8:00 PM
 Reply-To: "Aging Clinical and Experimental Research (ACER)" <sankari.gireesa@springernature.com>
 To: Carla Ferreira do Nascimento <nascimento.cfd@gmail.com>

Dear Ms. do Nascimento,

Thank you for submitting your manuscript,

"Functional Mobility and 10-year All-Cause and Cause-Specific Mortality in Older People from São Paulo, Brazil", to
 Aging Clinical and Experimental Research

During the review process, you can keep track of the status of your manuscript by accessing the Journal's website.

Your username is: carlafn

If you forgot your password, you can click the 'Send Login Details' link on the EM Login page at
<https://www.editorialmanager.com/acer/>.

With kind regards,

Springer Journals Editorial Office
 Aging Clinical and Experimental Research

Now that your article will undergo the editorial and peer review process, it is the right time to think about publishing your article as open access. With open access your article will become freely available to anyone worldwide and you will easily comply with open access mandates. Springer's open access offering for this journal is called Open Choice (find more information on www.springer.com/openchoice). Once your article is accepted, you will be offered the option to publish through open access. So you might want to talk to your institution and funder now to see how payment could be organized; for an overview of available open access funding please go to www.springer.com/oafunding. Although for now you don't have to do anything, we would like to let you know about your upcoming options.

****Our flexible approach during the COVID-19 pandemic****

If you need more time at any stage of the peer-review process, please do let us know. While our systems will continue to remind you of the original timelines, we aim to be as flexible as possible during the current pandemic.

This letter contains confidential information, is for your own use, and should not be forwarded to third parties.

Recipients of this email are registered users within the Editorial Manager database for this journal. We will keep your information on file to use in the process of submitting, evaluating and publishing a manuscript. For more information on how we use your personal details please see our privacy policy at <https://www.springernature.com/production-privacy-policy>. If you no longer wish to receive messages from this journal or you have questions regarding database management, please contact the Publication Office at the link below.

In compliance with data protection regulations, you may request that we remove your personal registration details at any time. (Use the following URL: <https://www.editorialmanager.com/acer/login.asp?a=r>). Please contact the publication office if you have any questions.

ANEXO III

14/04/2021

Universidade de São Paulo Mail - Age and Ageing AA-20-1394.R2

Carla Ferreira do Nascimento <carlafn@usp.br>

Age and Ageing AA-20-1394.R2

7 messages

Katy Ladbrook <aa@bgs.org.uk>
To: "carlafn@usp.br" <carlafn@usp.br>

Thu, Feb 18, 2021 at 7:56 AM

Dear Ms. Ferreira do Nascimento,

Cause-specific mortality prediction in older residents of São Paulo, Brazil: A machine learning approach (AA-20-1394.R2)

I am pleased to tell you that your submission has been accepted for publication.

Please complete and return the attached Author Statements so that we can release your final draft manuscript to the publishers, OUP. At present, the interval between acceptance and online publication is 4-5 weeks from receipt of your Author Statements.

I hope you will not mind my asking if you would also be prepared to act as a reviewer for Age and Ageing? This need not be an onerous commitment, as we would be guided by the number of papers you felt able to review each year. If you would like to join the team of peer reviewers, would you kindly let me know by return email.

Thank you for sending your manuscript to Age and Ageing. I do hope that you will send us more articles in the future.

With best wishes.

Yours sincerely

Professor Rowan Harwood
Editor

Disseminating your paper

Age and Ageing and the British Geriatrics Society use traditional and social media to maximise the impact of articles published in Age and Ageing. If you are planning any promotions we would be pleased to be included or to collaborate on a joint activity. Please see our author resource [Disseminating Your Paper](#) for suggestions to increase the exposure to your work and make it discoverable to a wider audience.

What happens next

LICENCE TO PUBLISH

In order to publish your article, Oxford University Press requires that you complete a licence agreement online. A link to the online licensing system will be provided to you by the Production Editor at Oxford University Press in due

ANEXO IV

14/04/2021

Universidade de São Paulo Mail - Journal of Gerontology: Medical Sciences - Manuscript ID JGMS-2021-RES-0205

Carla Ferreira do Nascimento <carlafn@usp.br>

Journal of Gerontology: Medical Sciences - Manuscript ID JGMS-2021-RES-0205

1 message

Journal of Gerontology: Medical Sciences <onbehalf@manuscriptcentral.com>

Thu, Mar 11, 2021 at 12:05 AM

Reply-To: JGeronMed@geron.org

To: carlafn@usp.br, carla_fn@hotmail.com

Cc: carlafn@usp.br, carla_fn@hotmail.com, andrefmb@usp.br, yedaenf@usp.br, alexdiasporto@usp.br

10-Mar-2021

Dear Ms. do Nascimento,

Your manuscript entitled "Early identification of older individuals at risk of mobility decline with machine learning" has been successfully submitted online and is presently being given full consideration for publication in the Journal of Gerontology: Medical Sciences.

Your manuscript ID is JGMS-2021-RES-0205.

Please mention the above manuscript ID in all future correspondence or when calling the office for questions. If there are any changes in your street address or e-mail address, please log in to ScholarOne Manuscripts at <https://mc.manuscriptcentral.com/jgms> and edit your user information as appropriate.

You can also view the status of your manuscript at any time by checking your Author Center after logging in to <https://mc.manuscriptcentral.com/jgms>.

Please note that all future communications concerning this manuscript will be directed to the Corresponding Author only.

Thank you for submitting your manuscript to the Journal of Gerontology: Medical Sciences.

Bring Customized Journal Alerts to Your Inbox

Register to receive free alerts from The Gerontologist and the Journals of Gerontology, including e-mail tables of contents, advance access alerts, and CiteTrack citation and keyword alerts! These and other updates are a free service of Oxford Journals' "My Account." Visit www.oxfordjournals.org/register to sign up.

Yours sincerely,

Kathleen Jackson

Journal of Gerontology: Medical Sciences

P.S. Become a Member of GSA and Receive the Journal of Gerontology: Medical Sciences.

As a member of the Gerontological Society of America, you can receive your choice of two of three of our preeminent journals. Plus, receive online access to all three. Become a member and experience the many benefits, learn more at www.geron.org/membership.

CURRÍCULO LATTES

Carla Ferreira do Nascimento

Endereço para acessar este CV: <http://lattes.cnpq.br/5149900111405622>

ID Lattes: **5149900111405622**

Última atualização do currículo em 15/06/2021

É aluna de doutorado do Programa de Pós-graduação em Saúde Pública da Universidade de São Paulo, mestra pelo mesmo programa, na área de epidemiologia, e membro do LABDAPS (Laboratório de Big Data e Análise Preditiva em Saúde), onde desenvolve pesquisas na área de saúde pública e epidemiologia. Tem graduação em fisioterapia pela Escola Bahiana de Medicina e Saúde Pública, com formação no Conceito Bobath e Facilitação Neuromuscular Proprioceptiva (PNF). Atualmente é professora substituta no Departamento de Fisioterapia do Instituto de Ciências da Saúde da Universidade Federal da Bahia e atua na preceptoría do programa de Residência em Fisioterapia Neurofuncional do Hospital Geral Roberto Santos, onde desenvolve atividades assistenciais, de ensino e pesquisa. Apresenta interesse especial pelos temas: controle postural e mobilidade funcional no envelhecimento e após Acidente Vascular Cerebral. **(Texto informado pelo autor)**

Identificação

Nome	Carla Ferreira do Nascimento
Nome em citações bibliográficas	NASCIMENTO, C. F.;NASCIMENTO, C.;Carla Ferreira do Nascimento;NASCIMENTO, CARLA;DO NASCIMENTO, CARLA FERREIRA;NASCIMENTO, C. F. D.;Nascimento, Carla Ferreira do;DO NASCIMENTO, CARLA F.;FERREIRA DO NASCIMENTO, CARLA
Lattes iD	http://lattes.cnpq.br/5149900111405622
Orcid iD	https://orcid.org/0000-0002-0054-277X

Endereço

Endereço Profissional	Universidade de São Paulo, Faculdade de Saúde Pública. Av. Doutor Arnaldo, 715 Pacaembu 01246904 - São Paulo, SP - Brasil Telefone: (11) 30617737
------------------------------	---

Formação acadêmica/titulação

2016	Doutorado em andamento em Saúde Pública (Conceito CAPES 6). Universidade de São Paulo, USP, Brasil. Título: Declínio da mobilidade e sobrevida em idosos do município de São Paulo: Análise longitudinal multinível do Estudo SABE (2000-2016), Orientador: Alexandre Dias Porto Chiavegatto Filho. Bolsista do(a): Conselho Nacional de Desenvolvimento Científico e Tecnológico, CNPq, Brasil. Palavras-chave: mobilidade funcional; análise multinível; sobrevida; Idosos.
2014 - 2016	Mestrado em Saúde Pública (Conceito CAPES 6). Universidade de São Paulo, USP, Brasil. Título: Determinantes sociais da mobilidade funcional e quedas em idosos do município de São Paulo: uma análise multinível, Ano de Obtenção: 2016. Orientador: Alexandre Dias Porto Chiavegatto Filho. Bolsista do(a): Fundação de Amparo à Pesquisa do Estado de São Paulo, FAPESP, Brasil. Palavras-chave: Idosos; quedas; determinantes sociais; análise multinível. Grande área: Ciências da Saúde Grande Área: Ciências da Saúde / Área: Fisioterapia e Terapia Ocupacional / Subárea: Geriatria e Gerontologia.
2006	Especialização em andamento em Fisioterapia Neurofuncional. (Carga Horária: 360h). Faculdade Social da Bahia, FSBA, Brasil. Título: Treino de resistência - Fortalecimento muscular e condicionamento aeróbico em pacientes neurológicos. Orientador: Élen Beatriz Pinto.
2001 - 2005

Alexandre Dias Porto Chiavegatto Filho

Bolsista de Produtividade em Pesquisa do CNPq - Nível 2

Endereço para acessar este CV: <http://lattes.cnpq.br/5517850224634709>

ID Lattes: **5517850224634709**

Última atualização do currículo em 05/07/2021

Possui graduação em Economia pela USP, doutorado em Saúde Pública pela USP e pós-doutorado na Universidade de Harvard. É Professor Livre Docente do Departamento de Epidemiologia da Faculdade de Saúde Pública da USP e orientador dos programas de pós-graduação de Saúde Pública e de Epidemiologia da USP. Atuou como professor convidado (2016 e 2020) e pesquisador visitante (2017 e 2019) na Universidade de Harvard. Em 2020, recebeu o Prêmio Abril e Dasa de Inovação Médica (Categoria: Prevenção). Nos últimos anos, tem sido o Pesquisador Principal de projetos de inteligência artificial em saúde financiados pela FAPESP, CNPq, Microsoft e Fundação Lemann. É membro do Conselho de Editores da Revista de Saúde Pública. Em 2015-2016 foi responsável pelo curso online Big Data em Saúde no Brasil, da parceria USP-Coursera, que teve mais de 8.500 alunos matriculados e representantes de todos os Estados brasileiros. É o diretor do Laboratório de Big Data e Análise Preditiva em Saúde (Labdaps) da FSP/USP. Atualmente é o coordenador da rede IACOV-BR (Inteligência Artificial para Covid-19 no Brasil), que tem como objetivo desenvolver algoritmos de machine learning para o diagnóstico e prognóstico de covid-19 nas cinco regiões brasileiras. Tem experiência em pesquisas na área de saúde pública, com ênfase em estatísticas de saúde e machine learning. **(Texto informado pelo autor)**

Identificação

Nome	Alexandre Dias Porto Chiavegatto Filho
Nome em citações bibliográficas	Chiavegatto Filho, A.D.P.;CHIAVEGATTO FILHO, A. D. P.;Chiavegatto Filho, Alexandre Dias Porto;Filho, Alexandre Dias Porto Chiavegatto;Chiavegatto Filho, Alexandre DP;Chiavegatto, Alexandre Dias Porto;Chiavegatto Filho, Alexandre;Filho, Alexandre Chiavegatto;CHIAVEGATTO FILHO, ALEXANDRE D P;CHIAVEGATTO FILHO, A D P;CHIAVEGATTO FILHO, ALEXANDRE D. P.;DIAS PORTO CHIAVEGATTO FILHO, ALEXANDRE;Chiavegatto Filho, A. D. P.;CHIAVEGATTO FILHO, ALEXANDRE D. P.
Lattes iD	http://lattes.cnpq.br/5517850224634709

Endereço

Endereço Profissional	Faculdade de Saúde Pública. Av. Dr. Arnaldo, 715 Cerqueira César 01246904 - São Paulo, SP - Brasil Telefone: (11) 30617914 URL da Homepage: https://www.fsp.usp.br/labdaps
------------------------------	--

Formação acadêmica/titulação

2007 - 2010	Doutorado em Saúde Pública (Conceito CAPES 6). Universidade de São Paulo, USP, Brasil. com período sanduíche em Harvard School of Public Health (Orientador: Ichiro Kawachi). Título: Efeito da desigualdade de renda na mortalidade do Município de São Paulo., Ano de obtenção: 2010. Orientador: Sabina Léa Davidson Gottlieb. Bolsista do(a): Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, CAPES, Brasil. Palavras-chave: desigualdade de renda; epidemiologia; mortalidade; São Paulo. Grande área: Ciências da Saúde Grande Área: Ciências da Saúde / Área: Saúde Coletiva / Subárea: Saúde Pública. Graduação em Economia. Universidade de São Paulo, USP, Brasil.
2008 - 2014	