

MODELO DE PREVISÃO DE DEMANDA PARA SUPRIMENTOS DE AJUDA HUMANITÁRIA NO ESTADO DE SÃO PAULO

María Fernanda Carnero Quispe (Universidade de São Paulo)

Alexandre Duarte (Universidade de São Paulo)

Hugo Tsugunobu Yoshida Yoshizaki (Universidade de São Paulo)



As mudanças climáticas estão intensificando desastres, causando sérias perdas humanas, materiais, econômicas e ambientais para comunidades. A logística humanitária surge com o objetivo de enfrentar esse desafio, visando eficiência no fluxo de ajuda para aliviar o sofrimento dos afetados pelos desastres. Nesse sentido, os modelos de previsão de demanda são cruciais em operações humanitárias, para que seja possível adquirir a quantidade necessária de suprimentos de ajuda humanitária e atender com maior velocidade as pessoas afetadas por desastres, evitando a superestimação ou a subestimação consideráveis da demanda. Em São Paulo, desastres como deslizamentos e inundações são comuns, especialmente durante anos de El Niño. O objetivo desse trabalho, portanto, é desenvolver um modelo de previsão de demanda por suprimentos de ajuda humanitária, baseado na literatura já existente. O novo modelo proposto representa um avanço no sentido de reduzir significativamente a superestimação da demanda, permitindo reduzir custos de aquisição, estoque e perdas, alocando de forma mais eficiente os escassos recursos financeiros disponíveis para operações de ajuda humanitária.

Palavras-chave: Modelo de previsão de demanda, Logística humanitária, Dados de contagem, Modelo Binomial Negativo com Inflação de Zeros.

1. Introdução

As mudanças climáticas estão causando desastres mais frequentes e severos (JUNIOR *et al.*, 2020). Um desastre refere-se a um evento que interrompe seriamente o funcionamento de uma comunidade e causa perdas humanas, materiais, econômicas ou ambientais que excedem a capacidade da comunidade ou sociedade de lidar usando seus próprios recursos (UNISDR, 2015).

Van Wassenhove (2006) classifica os desastres quanto à sua origem e velocidade de início. Quanto à origem, podem ser naturais (como inundações ou terremotos) ou causados pelo homem (como derramamentos químicos ou migrações em massa). Quanto à velocidade de início, podem ser de início súbito (como tornados ou ataques terroristas) ou catástrofes de início lento (como secas ou crises políticas).

Nesse contexto, emerge o conceito de logística humanitária definido como o planejamento, implementação e controle do fluxo eficiente de bens, materiais e informações desde sua origem até o consumidor final, com o objetivo de aliviar o sofrimento dos afetados (THOMAS e KOPCSAK, 2005).

Um dos desafios das operações humanitárias é a demanda irregular de suprimentos de ajuda humanitária (KOVACS e SPENS, 2007). Diante dessa situação, torna-se evidente a importância do desenvolvimento de modelos de previsão de demanda que permitam tomar decisões em relação a outras operações, como entrega de bens de ajuda humanitária (BISWAS *et al.*, 2024). Os desastres em São Paulo são principalmente deslizamentos de encostas, inundações, erosão e tempestades (AMARAL e GUTHJAR, 2015), e estão fortemente relacionados às chuvas. Por isso, nos anos em que ocorre o fenômeno climático "El Niño" (que são mais chuvosos) a incidência desses desastres também aumenta (PAREJA, 2022).

Para prever a demanda de suprimentos de ajuda humanitária no estado de São Paulo, Pareja, Yoshizaki e Fávero (2022) desenvolveram um modelo multinível binomial negativo com inflação de zeros, utilizando como preditores a população, vulnerabilidade e a ocorrência de anomalia climática para cada município deste estado. Entretanto, observou-se que esse modelo tende a superestimar em mais de 100% a demanda de anos com a incidência do fenômeno climático "El Niño".

Com base no exposto, o objetivo deste artigo é desenvolver um novo modelo de previsão de demanda por suprimentos de ajuda humanitária para o estado de São Paulo, Brasil, que refine e aumente a precisão do modelo proposto por Pareja, Yoshizaki e Favero (2022), incorporando um novo preditor.

Depois desta introdução, o resto do artigo é organizado da seguinte forma. A seção 2 apresenta

a revisão da literatura sobre modelos de previsão de demanda em logística humanitária. A seção 3 apresenta a metodologia utilizada, abrangendo a seleção de preditores e a seleção do modelo. A seção 4 apresenta os resultados do novo modelo em comparação com o desenvolvido por Pareja Yale (2022). Finalmente, a seção 5 apresenta as conclusões.

2. Revisão da Literatura

Após um desastre, é comum que recursos essenciais, como comida, água, abrigo e suprimentos médicos, não estejam prontamente disponíveis em quantidades suficientes para atender à demanda repentinamente aumentada (BISWAS *et al.*, 2024). A estimação desta demanda representa um desafio significativo e requer a geração de modelos para estimar a quantidade necessária de ajuda humanitária (NAIR; RASHIDI; DIXIT, 2017). Além disso, é crucial para apoiar decisões estratégicas na gestão de operações em todos os setores de produção e serviços (ABREU; SANTOS; BARBOSA-POVOA, 2023).

A Tabela 1 apresenta uma síntese de artigos relacionados à previsão de demanda em diferentes contextos de desastre, incluindo o método utilizado, o tipo de desastre abordado e a aplicação geográfica. Os estudos variam desde modelos de regressão linear múltipla até métodos mais avançados baseados em inteligência artificial.

Tabela 1. Artículos relacionados a previsão de demanda

Autor (Ano)	Método	Tipo de desastre	Aplicação
Nair <i>et al.</i> (2017)	Múltipla regressão linear Equações estruturais Redes Neurais Artificiais	Geral	Austrália
Pareja <i>et al.</i> (2022)	Modelo multinível binomial negativo com inflação de zeros	São Paulo, Brasil	Geral
Paul <i>et al.</i> (2022)	Modelo de previsão conjunto	EUA	Geral
Nguyen <i>et al.</i> (2022)	Aprendizado de Máquina	EUA	Furacão
Abreu <i>et al.</i> (2023)	Inteligência Artificial	Geral	Portugal
Biswas <i>et al.</i> (2024)	Inteligência Artificial	Terremoto	Turquia

A previsão de demanda para suprimentos de ajuda humanitária pode ser abordada em diferentes níveis, tanto macro quanto micro (PAUL; DAVIS, 2022). A maioria dos estudos sobre previsão de demanda tende a se concentrar em uma perspectiva macro. No entanto, isso pode apresentar desafios quando se trata de uma área geográfica maior. Diante dessa questão, Pareja, Yoshizaki e Favero (2022) propõem um modelo de previsão de demanda que avalia a demanda de cada um dos municípios que compõem uma determinada região. Essa abordagem micro permite uma compreensão mais precisa das necessidades específicas de cada localidade, facilitando a alocação eficiente de recursos humanitários.

Além disso, Pareja Yale *et al.* (2022), ao examinarem os dados históricos da demanda em São Paulo, Brasil, revelaram que em muitos municípios a demanda era zero. Isso evidencia a limitação dos modelos convencionais em capturar a verdadeira variação da demanda, justificando assim a necessidade de modelos mais sofisticados, como os modelos com inflação de zeros.

Nguyen *et al.* (2022) indicam que em zonas geográficas com desastres relacionados ao clima, precisa-se utilizar informações meteorológicas como preditor para a demanda de ajuda humanitária. Neste contexto, Pareja, Yoshizaki e Favero (2022) encontraram que, em São Paulo, nos anos com a anomalia climática "El Niño", ocorre um aumento substancial na demanda por suprimentos de ajuda humanitária.

No entanto, o modelo gera uma superestimação para os anos com tal fenômeno. Diante dessa situação, é fundamental considerar outros preditores que possam contribuir para a obtenção de resultados mais precisos, tais como a identificação de áreas com maior risco de desastre (BISWAS *et al.*, 2024).

3. Metodologia


Um fator-chave para uma resposta eficiente em operações humanitárias pós-desastre é a previsão precisa da demanda por suprimentos de ajuda. Isso permite que as autoridades competentes tomem decisões informadas e priorizem seus esforços para atender às necessidades imediatas das pessoas afetadas.

Ao prever adequadamente a demanda por suprimentos de ajuda humanitária, os tomadores de decisão podem otimizar a alocação de recursos, garantindo a disponibilidade rápida de materiais vitais e suprimentos durante a fase de resposta a desastres (Biswas *et al.*, 2024).

Como observado por Pareja *et al.* (2022), as séries históricas de demanda por suprimentos de ajuda humanitária no estado de São Paulo contêm um excesso de zeros. Esse comportamento pode ser atestado na Figura 1, que exibe um histograma da demanda por suprimentos de ajuda

humanitária no estado de São Paulo considerando dados entre 2015 e 2020 disponibilizados pela Coordenadoria Estadual de Proteção e Defesa Civil (CEPDEC-SP).

Figura 1 - Histograma da demanda por suprimentos de ajuda humanitária no estado de São Paulo (2015-2020).



Fonte: Elaborado pelos autores. Banco de dados disponibilizado pela CEPDEC-SP.

De acordo com Fávero e Belfiore (2017), se tratando de modelos de regressão para dados de contagem, algumas verificações são necessárias para determinar qual o modelo é estatisticamente mais adequado.

Primeiramente, deve-se verificar se há superdispersão nos dados da variável dependente. Em caso de haver superdispersão, deve-se optar por um modelo binomial negativo; em caso contrário, deve-se optar por um modelo Poisson. No estudo de Pareja Yale *et al.* (2022) foi considerado um modelo binomial negativo. Porém, é necessário verificar se há superdispersão nos dados da variável dependente (FÁVERO; BELFIORE, 2017).

Conforme pode ser observado na Tabela 2, a variância da variável “demanda” é muitas vezes superior ao valor da média. Isso, isoladamente, já é um indício de superdispersão nos dados. Cameron e Trivedi (1990) estabeleceram um teste para verificar se há superdispersão em uma amostra de dados. A hipótese nula é de que um modelo de Poisson é adequado para os dados, pois a média e a variância da amostra são iguais (isto é, não há superdispersão nos dados).

Executando o teste, verificamos que a suspeita inicial de superdispersão nos dados se verifica, tendo em vista o p-valor obtido no teste de Cameron e Trivedi (1990), que pode ser visto na Tabela 2. Ao nível de significância de 95%, rejeita-se a hipótese nula do teste, e, portanto, o modelo Poisson não é adequado para os dados de demanda por suprimentos de ajuda humanitária. Desse modo, de acordo com Fávero e Belfiore (2017), deve-se prosseguir com o modelo binomial negativo.

Tabela 2 - Média e variância da amostra; p-valor do teste de Cameron e Trivedi (1990).

Teste de Cameron e Trivedi (1990)		
H_0 : A variância é igual a média		
H_1 : A variância é diferente da média		
Média	Variância	P-valor
241,86	1 654 561	0,000051

Em seguida, deve-se verificar se há uma quantidade excessiva de zeros na variável dependente. Em caso positivo, deve-se optar por um modelo inflacionado de zeros; em caso negativo, deve-se seguir com o modelo convencional.

Portanto, apesar dos indícios de existência de inflação de zeros nos dados de demanda por suprimentos de ajuda humanitária, é necessário atestar estatisticamente esse excesso de zeros (FÁVERO; DUARTE; SANTOS, 2024).

O próximo passo é verificar se de fato existe excesso de zeros na amostra. Como foi observado previamente, no histograma apresentado na Figura 1, há um forte indicativo de que a amostra possui um excesso de zeros.

Vuong (1989) estabeleceu um teste para verificar se há uma quantidade estatisticamente excessiva de zeros na variável dependente. De acordo com Fávero e Belfiore (2017), valores positivos da estatística-z e um p-valor < 0.05 implicam na rejeição da hipótese nula; portanto, há evidência estatística de excesso de zeros na variável dependente. Ao executar o teste para a variável demanda, rejeita-se a hipótese nula, tendo em vista os valores obtidos para a estatística-z e o seu respectivo p-valor, que podem ser vistos na Tabela 3.

Tabela 3 - Estatística-z e p-valor do teste de Vuong (1989).

Teste de Vuong (1989)	
H_0 : A variável não tem excesso de zeros	
H_1 : A variável tem excesso de zeros	
Estatística-z	P-valor
2,15	0,0156

Logo, levando em consideração o resultado do teste de superdispersão e o teste de excesso de zeros, o modelo mais adequado para os dados de contagem de demanda por suprimentos de


ajuda humanitária no estado de São Paulo é um modelo binomial negativo inflacionado de zeros.

Este artigo propõe uma versão modificada do modelo binomial negativo inflacionado de zeros proposto por Pareja Yale *et al.* (2022), integrando uma nova variável preditora “risco de desastre”, melhorando a precisão do modelo de previsão de demanda, tendo em vista que o modelo original gerou uma superestimação de 106% na demanda.

O “risco de desastre” é uma variável qualitativa que pode ser categorizada em "risco de desastre baixo", "risco de desastre médio" e "risco de desastre alto". Ao gerar variáveis *dummy* (FÁVERO; BELFIORE, 2017), temos as variáveis binárias “risco baixo” e “risco médio”, sendo que “risco alto” é representado pelo valor zero nas duas variáveis anteriores.

Para determinar o risco de desastre de cada cidade do estado de São Paulo, consideramos a classificação fornecida pela Secretaria do Meio Ambiente do Governo do Estado de São Paulo (São Paulo, 2014). A classificação de risco de deslizamentos e inundação pode ser vista na Figura 2. Os mapas fornecem sete classes de risco, que agregamos em três classes, ponderando essa classificação pelos dados reais de demanda por suprimentos de socorro de cada cidade.

Figura 2 - Mapa de perigo de deslizamentos (a) e mapa de perigo de inundações (b) no estado de São Paulo.



Fonte: São Paulo (2014).

Além da variável “risco”, as seguintes variáveis preditoras também foram consideradas no modelo original (PAREJA; YOSHIKAZI; FÁVERO, 2022): “população”, “anomalia climática” e “vulnerabilidade”. A Tabela 4 oferece um descritivo de todas as variáveis preditoras.

Tabela 4 - Descrição das variáveis preditoras utilizadas no modelo proposto.

Variável preditora	Descrição	Fonte
População	Projeções populacionais baseadas no Censo Demográfico 2010 do Instituto Brasileiro de Geografia e Estatística (IBGE).	IBGE (2010)
Anomalia climática	Monitoramento das variações de temperatura, precipitação, pressão atmosférica e circulação atmosférica no Oceano Pacífico Equatorial.	NOAA (2022)
Vulnerabilidade	Caracterização socioeconômica por município do Estado de São Paulo. Os dados são do Índice de Vulnerabilidade Social de São Paulo (IPVS).	SEADE (2010)
Risco de desastres	Variável categórica baseada no mapeamento de perigos, vulnerabilidades e riscos no estado de São Paulo.	São Paulo (2014)

Fonte: Pareja, Yoshizaki e Fávero (2022).

De acordo com Fávero e Belfiore (2017), o modelo binomial negativo inflacionado de zeros (ZINB) consiste em dois componentes: o Componente com Inflação de Zeros e o Componente Binomial Negativo. O Componente com Inflação de Zeros modela a probabilidade de excesso de zeros nos dados. No novo modelo proposto, os preditores relacionados a esse componente são “risco de desastre baixo”, “risco de desastre médio” e “vulnerabilidade”. Além disso, temos o Componente Binomial Negativo, que modela a distribuição de contagens de eventos, assumindo que os dados não são zeros. No novo modelo proposto, os preditores relacionados a esse componente são “população” e “anomalia climática”.

A Equação 1 apresenta o modelo ZINB no nosso estudo:

$$d_i = \left(1 - \frac{1}{1 + e^{-(a+cv.v_i+cr_b.r_{b,i}+cr_m.r_{m,i})}}\right) \cdot e^{(b+ca.a_i+cp.p_i)} \quad (1)$$

Onde:

d_i : Demanda por suprimentos de ajuda humanitária no município i .

v_i : Vulnerabilidade do município i (possui coeficiente associado cv).

a_i : Anomalia climática no município i (binária; possui coeficiente associado ca).

p_i : População do município i (possui coeficiente associado cp).

$r_{b,i}$: Risco baixo de desastre do município i (binária; possui coeficiente associado cr_b).

$r_{m,i}$: Risco médio de desastre do município i (binária; possui coeficiente associado cr_m).

4. Resultados

Pareja, Yoshizaki e Fávero (2022) desenvolveu um modelo Multinível Binomial Negativo com Inflação de Zeros que considerou “anomalia climática” e “população” no componente binomial negativo, a “vulnerabilidade” da população (considerando uma escala qualitativa do índice IPVS mencionado na Tabela 4) no componente de inflação de zeros e um componente multinível usando clusters obtidos a partir do método de agrupamento k-médias. Os coeficientes do modelo podem ser vistos na Tabela 5.

Tabela 5 – Estimação do modelo de Pareja, Yoshizaki e Fávero (2022) e o modelo proposto.

	Pareja, Yoshizaki e Fávero (2022)	Modelo proposto
Variável	Coeficiente	
Componente Binomial Negativo		
Intercepto	3.96	2.98
Anomalia climática	1.99	1.26
População (logaritmo natural)	0.26	0.35
Componente Inflacionado de Zeros		
Vulnerabilidade moderada	1.62	-
Vulnerabilidade muito alta	-1.43	-
Vulnerabilidade (IPVS index)	-	-0.79
Risco baixo	-	3.41
Risco médio	-	1.15
Intercepto	1.74	4.65
Componente multinível		
Cluster a	1.31	-
Cluster b	-1.21	-
Cluster c	0.19	-
Ajuste dos modelos		
Log-verossimilhança (LL)	-1954	-1896
Critério de Informação de Akaike (AIC)	3935	3810

Comparando os valores reais de demanda com os valores previstos, foi observado que o modelo de Pareja, Yoshizaki e Fávero (2022) superestimou a demanda total em 106%. Em cenários com anomalia climática, o modelo superestimou a demanda em 181%; já em cenários sem anomalia climática a demanda foi subestimada em 31%.

Neste artigo, propomos um novo modelo de previsão de demanda, que contorna o problema de superestimação considerando a “vulnerabilidade” da população (neste caso, utilizando o índice IPVS quantitativo) e uma variável de “risco” (considerando o mapa apresentado na Figura 2) no componente de inflação de zeros, enquanto o componente binomial negativo permanece o mesmo. Não consideramos o componente multinível, tendo em vista que o mesmo não melhorou significativamente o modelo de previsão de demanda. Os coeficientes do modelo podem ser vistos na Tabela 5.

Comparando os valores reais de demanda com os valores previstos, o novo modelo proposto superestimou a demanda total em apenas 14%. Em cenários com anomalia climática, o modelo superestimou a demanda em 38%, enquanto em cenários sem anomalia climática a demanda foi subestimada em 29%.

Além da notável melhoria na previsão da demanda, observa-se que os valores LL e AIC associados ao modelo proposto são inferiores aos do modelo original proposto por Pareja, Yoshizaki e Fávero (2022), sugerindo que o modelo proposto tem um melhor desempenho.

Para reforçar essa constatação, foi realizado o Teste de Razão de Verossimilhança de Wilks (1938), que resultou em um p-valor menor que 0.05. Isso permite concluir que o modelo proposto é significativamente melhor em ajustar aos dados de demanda por suprimentos de ajuda humanitária do que o modelo de Pareja, Yoshizaki e Fávero (2022).

Tabela 6 – Razão de verossimilhança (LR) e valor-p do Teste de razão de verossimilhança de Wilks (1938)


Teste de razão de verossimilhança de Wilks (1938)				
H_0 : O modelo 1 têm desempenho similar em ajustar os dados do que o modelo 2				
H_1 : O modelo 1 é significativamente melhor em ajustar os dados do que o modelo 2				
	LL	df	LR	P-valor
Modelo de Pareja, Yoshizaki e Fávero (2022)	-1954			
Modelo Proposto	-1896	1	116	4.75×10^{-27}

O modelo de previsão de demanda, dado pela Equação 1, pode ser reescrito com os valores obtidos para os coeficientes apresentados na Tabela 5. A equação reescrita está explicitada na Equação 2.

$$d_i = \left(1 - \frac{1}{1 + e^{-(4,65 - 0,79.v_i + 3,41.r_{b,i} + 1,15.r_{m,i})}}\right) \cdot e^{(2,98 + 1,26.a_i + 0,35.p_i)} \quad (2)$$

Utilizando o modelo apresentado na Equação 2, a distribuição da demanda por suprimentos de ajuda humanitária no estado de São Paulo teria a distribuição espacial mostrada na Figura 3.

Figura 3 - Distribuição espacial da demanda por suprimentos de ajuda humanitária no estado de São Paulo.



5. Conclusões

Uma das principais operações pós-desastre é a entrega de suprimentos de ajuda humanitária. Diante disso, é importante desenvolver bons modelos de previsão de demanda que permita adquirir a quantidade necessária de suprimentos de ajuda humanitária para atender com maior velocidade as pessoas afetadas pelo desastre.

É fundamental selecionar um modelo que seja estatisticamente adequado para evitar a superestimação ou a subestimação consideráveis da demanda, tendo em vista que os dois cenários são prejudiciais para a eficiência das operações de ajuda humanitária.

Em cenários de superestimação da demanda aumenta-se desnecessariamente os custos com aquisição e estoque de suprimentos, bem como há risco de perdas, caso os mesmos sejam perecíveis. Além disso, os recursos para operações humanitárias são, em geral, escassos. Portanto, precisam ser eficientemente alocados em atividades que priorizem aliviar o sofrimento de pessoas vulneráveis.

Os casos de subestimação da demanda também são problemáticos, pois os afetados pelos desastres precisarão de mais tempo para serem assistidos com suprimentos básicos para a sua sobrevivência, aumentando o sofrimento dessas pessoas.

As iniciativas de gerar novos modelos, conforme foi feito por Pareja, Yoshizaki e Fávero (2022), são fundamentais para otimizar as operações de distribuição de suprimentos de ajuda humanitária. Não obstante, esses trabalhos requerem uma constante atualização e aprimoramento com o objetivo de obter melhores resultados.

Este trabalho propôs um modelo de previsão de demanda por suprimentos de ajuda humanitária baseado no modelo proposto por Pareja, Yoshizaki e Fávero (2022). Este novo modelo foi capaz de reduzir significativamente a superestimação da demanda do modelo anterior. Para os anos com anomalia climática, a superestimação foi de 106% para 38%.

Uma limitação do modelo proposto é o tamanho da amostra considerada, de apenas 5 anos, onde em só um deles houve anomalia climática ("El Niño"). Outra limitação reside na escassez de estatísticas e métricas relacionadas a desastres a um nível municipal (a maioria são a nível estadual ou regional), o que permitiria melhorar a precisão do modelo.

Para trabalhos futuros, é relevante gerar modelos de previsão de demanda por suprimentos de ajuda humanitária para outros estados brasileiros e para outros países. Entretanto, esses modelos precisam ser adaptados aos tipos de desastres e às particularidades de cada área geográfica estudada. Outra recomendação seria continuar com o processo de melhoria do modelo proposto, tendo em vista que ainda há superestimação de 38% para anos em que há anomalia climática e subestimação de 29% para anos em que não há anomalia climática.

REFERÊNCIAS

ABREU, P.; SANTOS, D.; BARBOSA-POVOA, A. Data-driven forecasting for operational planning of emergency medical services. **Socio-Economic Planning Sciences**, v. 86, p. 101492, 2023.

AMARAL, R. e GUTJAHR M. Desastres Naturais. 2015. Disponível em: <https://www.preventionweb.net/files/43291_sendaiframeworkfordrren.pdf>.

BISWAS, S. et al. An AI-based framework for earthquake relief demand forecasting: A case study in Türkiye. **International Journal of Disaster Risk Reduction**, v. 102, p. 104287, 2024.

CAMERON, A.; TRIVEDI, P. Regression-based tests for overdispersion in the Poisson model. **Journal of econometrics**, v. 46, n. 3, p. 347-364, 1990.

CEPDEC. Histórico. 1995. Disponível em: <<http://www.defesacivil.sp.gov.br/historico>>.

FÁVERO, L.; BELFIORE, P. **Manual de análise de dados: estatística e modelagem multivariada com Excel®, SPSS® e Stata®**. Elsevier Brasil, 2017.

FÁVERO, L.; DUARTE, A.; SANTOS, H. A New Computational Algorithm for Assessing Overdispersion and Zero-Inflation in Machine Learning Count Models with Python. **Computers**, v. 13, n. 4, p. 88, 2024.

NAIR, D. J.; RASHIDI, T.; DIXIT, V. Estimating surplus food supply for food rescue and delivery operations. **Socio-Economic Planning Sciences**, 57, p. 73-83, 2017.

NGUYEN, L. et al. Forecasting people's needs in hurricane events from social network. **IEEE Transactions on Big Data**, v. 8, n. 1, p. 229-240, 2019.

NOAA. **El Nino Southern Oscillation (ENSO) Diagnostic Discussion**. 2022. Disponível em: <https://www.cpc.ncep.noaa.gov/products/analysis_monitoring/enso_advisory/>.

PAREJA, C. **Previsão da demanda de suprimentos de socorro com aplicação na localização de depósitos da Defesa Civil do estado de São Paulo**. 2022. Tese de Doutorado. Universidade de São Paulo.

PAREJA, C.; YOSHIKAZI, H.; FÁVERO, L. A New Zero-Inflated Negative Binomial Multilevel Model for Forecasting the Demand of Disaster Relief Supplies in the State of Sao Paulo, Brazil. **Mathematics**, v. 10, n. 22, p. 4352, 2022.

PAUL, S.; DAVIS, L. An ensemble forecasting model for predicting contribution of food donors based on supply behavior. **Annals of Operations Research**, p. 1-29, 2022.

SÃO PAULO. Unidades Básicas de Compartimentação do Meio Físico (UBC) do Estado de São Paulo. INSTITUTO GEOLÓGICO/COORDENADORIA DE PLANEJAMENTO AMBIENTAL, SECRETARIA DO MEIO AMBIENTE DO ESTADO DE SÃO PAULO, 2014.

SEADE. **Índice Paulista de Vulnerabilidade Social (IPVS)**. 2010. Disponível em: <<https://ipvs.seade.gov.br/view/index.php?selLoc=0&selTpLoc=2&prodCod=2>>.

IBGE (Instituto Brasileiro de Geografia e Estatística). **Censo demográfico**. 2010. Disponível em: <https://ftp.ibge.gov.br/Censos/Censo_Demografico_2010/resultados/tabelas_pdf/total_populacao_sao_paulo.pdf>.

UNISDR. Sendai framework for disaster risk reduction 2015–2030. 2015. Disponível em: <https://www.preventionweb.net/files/43291_sendaiframeworkfordrren.pdf>.

VAN WASSENHOVE, L. Humanitarian aid logistics: supply chain management in high gear. **Journal of the Operational research Society**, v. 57, n. 5, p. 475-489, 2006.

VUONG, Q. Likelihood ratio tests for model selection and non-nested hypotheses. **Econometrica: journal of the Econometric Society**, p. 307-333, 1989.

WILKS, S. The large-sample distribution of the likelihood ratio for testing composite hypotheses. **The annals of mathematical statistics**, v. 9, n. 1, p. 60-62, 1938.