

## Previsão de demanda de materiais de nutrição em um hospital público

**Najla Alemsan (UFSC)**  
[najla.alemsan@gmail.com](mailto:najla.alemsan@gmail.com)

**Ana Paula Lista (UFSC)**  
[anapaulalista@gmail.com](mailto:anapaulalista@gmail.com)

**Marina Cardoso Guimarães (UFSC)**  
[marinacguimaraes@yahoo.com.br](mailto:marinacguimaraes@yahoo.com.br)

**Guilherme Luz Tortorella (UFSC)**  
[gluztortorella@gmail.com](mailto:gluztortorella@gmail.com)

**Alexandre Leopoldo Gonçalves (UFSC)**  
[a.l.goncalves@ufsc.br](mailto:a.l.goncalves@ufsc.br)

*No setor de saúde, grande parte da demanda de materiais é marcada pela imprevisibilidade, seja pela criticidade, urgência ou quadro clínico dos pacientes. A gestão de materiais em organizações de saúde é uma das tarefas de maior complexidade, além de envolver materiais de alto custo tais como materiais de nutrição especial. Por esse motivo, há uma crescente busca por técnicas de planejamento de materiais. Dessa forma, o objetivo do trabalho foi comparar diferentes modelos de previsão de demanda das famílias de materiais de nutrição especial em um hospital público. Nas análises realizadas, foram comparados os resultados provenientes de cinco métodos para previsão de demanda: ARIMA, suavização exponencial, média móvel, regressão linear e redes neurais artificiais na previsão de demanda de 4 famílias: enterais, suplementos, mamadeiras e seringas. Os resultados demonstraram que a regressão linear se enquadrava de forma mais assertiva para representar o consumo de materiais cuja demanda era dependente de uma única variável, como é o caso das mamadeiras e seringas. Já em situações em que se dependia da estimação da soma de mais de uma variável, as análises demonstraram que o método ARIMA foi considerado o mais indicado para estimar a demanda destes produtos.*

*Palavras-chave: Previsão de Demanda, Planejamento de materiais, Nutrição Especial*



## 1. Introdução

No setor de saúde, grande parte da demanda de materiais é marcada pela imprevisibilidade, seja pela criticidade, urgência ou quadro clínico dos pacientes (CORREIA *et al.*, 2020). Segundo Gul e Celik (2020), a gestão de materiais em organizações de saúde é uma das tarefas de maior complexidade comparado a outros tipos de organizações. Por esse motivo, há uma crescente busca por maior eficiência de processos e otimização de recursos nos serviços de saúde relacionados ao planejamento e controle de materiais (BALCÁZAR-CAMACHO *et al.*, 2016).

Segundo a pesquisa de Moons *et al.* (2019) e Kumar *et al.* (2015), cerca de 46% do orçamento operacional de um hospital está relacionado a custos logísticos, 27% se refere a materiais e equipamentos e 19% compreende despesas de mão-de-obra. Nesse sentido, o planejamento e controle de materiais é visto como uma das melhores estratégias no sistema de apoio à decisão de operações hospitalares (ORDU *et al.*, 2019; REN *et al.*, 2020). Particularmente, os materiais de nutrição especial representam custos consideráveis no setor de saúde e por serem altamente perecíveis, a complexidade do planejamento e controle desses materiais agrava-se, demandando técnicas derivadas de outros setores tais como de previsão de demanda (SETYANINGSIH; BASRI, 2013).

Assim, com base nos argumentos levantados, o presente estudo possui como objetivo comparar diferentes modelos de previsão de demanda das famílias de materiais de nutrição especial em um hospital público. Inicialmente é realizada uma revisão teórica sobre métodos de previsão de demanda. Em seguida, um estudo de caso é conduzido em um hospital escola público de Santa Catarina, com o intuito de comparar a acurácia dentre os diferentes métodos quantitativos de previsão de demanda. Finalmente, uma análise dos resultados e direções de pesquisas futuras são apresentadas.

Em termos teóricos, este trabalho vem a contribuir com o corpo de literatura da área trazendo comparações entre diferentes modelos de previsão de demanda para materiais de nutrição especial. No que diz respeito à aplicação em termos práticos, vale ressaltar que as organizações de saúde ainda são poucos familiarizadas com métodos mais sofisticados de planejamento e controle de materiais (CALLENDER; GRASMAN, 2010; SETYANINGSIH; BASRI, 2013). Dessa forma, o trabalho proporciona *insights* para uma aplicação mais assertiva dos modelos de previsão de demanda, trazendo benefícios como redução de custos e evitando a falta de materiais vitais.

Além dessa seção introdutória, este artigo está estruturado da seguinte forma: a seção 2 apresenta uma revisão teórica sobre previsão de demanda. Na seção 3 é descrito o método proposto, cujos resultados são explanados na seção 4. Por fim, a seção 5 encerra o trabalho apresentando as conclusões e oportunidades para trabalhos futuros.

## 2. Revisão Teórica

A previsão de demanda objetiva estimar dados futuros baseada em modelos estatísticos, matemáticos ou subjetivos a fim de apoiar as tomadas de decisões das organizações (GOODWIN *et al.*, 2007). Os métodos de previsão de demanda podem ser divididos em duas grandes categorias: (i) métodos qualitativos e (ii) métodos quantitativos (YERPUDE *et al.*, 2017). Os métodos qualitativos referem-se àqueles que necessitam de opiniões de especialistas, tal como o método Delphi. Dentre os modelos quantitativos, há duas subdivisões: (i) métodos por séries temporais e (ii) métodos causais. Os métodos causais incluem os modelos por regressão, considerando uma ou mais variáveis preditoras e uma variável prevista. Já os métodos por séries temporais englobam Médias Móveis, ARIMA e Suavização Exponencial.

A previsão de séries temporais é uma área importante da previsão na qual observações anteriores da mesma variável são coletadas e analisadas para desenvolver um modelo que descreva o relacionamento subjacente (JOHNSTON *et al.*, 1999). O modelo ARIMA (*Autoregressive Integrated Moving Average*) possui como componentes: vetor auto regressivo (AR) e médias móveis (MA) (KALPAKIS *et al.*, 2001; WARGON *et al.*, 2009). No que diz respeito à suavização exponencial, é considerada uma técnica simples usada para suavizar e prever uma série de tempo sem a necessidade de ajustar um modelo paramétrico, o que torna o modelo atraente e explica seu uso generalizado (GELPER; FRIED, 2010).

Já a regressão linear é uma das técnicas mais populares e amplamente utilizadas para predição, pois é simples, intuitiva e produz modelos com alto grau de interpretabilidade (RISTANOSKI *et al.*, 2013; LALIS, 2016). Entretanto, a relação entre variável dependente e independente em muitas séries de dados pode ser não linear e complexa. Dessa forma, muitos estudos recentes têm focado no uso de técnicas de aprendizagem de máquina (p. ex. Rede Neural Artificial – RNA) como alternativa aos métodos tradicionais (CHAWLA *et al.*, 2019).


Grande parte dos estudos que integram previsão de demanda em serviços de saúde promovem uma comparação entre métodos para identificar o mais apropriado para o contexto em estudo, por exemplo os estudos de Cheng *et al.* (2016) e Fortsch e Khapalova (2016). Particularmente, quanto aos métodos mais aplicados em ambientes de serviços de saúde, destacam-se para séries

temporais os métodos ARIMA e Suavização Exponencial evidenciados pelos trabalhos de Earnest *et al.* (2005), Marcilio *et al.* (2013) e Arimie *et al.* (2019).

### 3. Método

O método de pesquisa do presente trabalho é composto por cinco etapas conforme apresentado na Figura 1.

Figura 1 - Etapas do método de estudo



Fonte: Elaborado pelos autores

Etapa 1: Primeiramente, a organização de serviços de saúde deve ser escolhida. Para tanto, algumas condições são desejáveis como o comprometimento da alta gerência e o setor hospitalar a ser analisado deve apresentar relevância na cadeia de suprimentos da organização investigada, aumentando o impacto das melhorias propostas.

Etapa 2: Após a seleção da organização de saúde e identificação do setor hospitalar em estudo são identificadas as famílias de produtos. Mais especificamente, os produtos são agrupados, com o auxílio de especialistas do setor, de modo a separar materiais de acordo com similaridades de suas características operacionais.

Etapa 3: Em sequência, inicia-se a coleta e preparação de dados quantitativos e qualitativos relacionados aos materiais em estudo. A coleta de dados quantitativos ocorre por meio do acesso a arquivos que contenham o histórico da demanda de tais materiais. Além disso, são coletados dados adicionais do hospital que possam estar correlacionados com a demanda dos materiais.

Etapa 4: Posteriormente, são testados cinco modelos de previsão de demanda nas séries de dados: ARIMA, Suavização Exponencial, Médias Móveis, Regressão Linear e Redes Neurais Artificiais. O *software* utilizado é o IBM SPSS Statistics<sup>®</sup>.

Etapa 5: Finalmente, os resultados dos métodos de previsão de demanda são analisados de forma a identificar o modelo que prevê resultados com maior acurácia. Dentre as maneiras de selecionar um modelo de previsão de demanda, destaca-se a análise a partir dos erros (KOCHAK; SHARMA, 2015). O MAPE (*Mean Absolute Percentage Error*) (Equação 1) é

considerado a métrica mais utilizada para verificar a acurácia do modelo de previsão de demanda em serviços de saúde devido às suas vantagens de independência de escalas e interpretabilidade (KIM; KIM, 2016), sendo por esse motivo utilizado nesta análise. Segundo Meneghini *et al.* (2018), 80% dos dados devem ser separados para elaboração do modelo de previsão de demanda (dados de treino) e 20% para realização dos testes de acurácia. Baihaqi *et al.* (2018) sugerem que valores de MAPE abaixo de 10% são ideais e até 15% são satisfatórios.

$$MAPE = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{D_t - M_t}{D_t} \right|$$

Onde,  $n$  = número total de observações de demanda,  $D_t$  = valor real da demanda no tempo  $t$  e  $M_t$  = valor de demanda calculado pelo modelo no tempo  $t$ .

#### 4. Resultados e discussões

A organização de saúde selecionada na pesquisa é um hospital-escola público localizado no sul do Brasil. O setor de estudo é de nutrição, mais especificamente a área de nutrição especial. A escolha foi realizada mediante a alta importância dos materiais ao paciente e a relevância financeira desses produtos no orçamento hospitalar. A nutrição especial agrupa 4 famílias: dietas enterais, suplementos e fórmulas infantis. As dietas enterais correspondem a um tipo de alimentação artificial em função da sua natureza de transporte fisiológico, podendo ser realizada com dietas orais, mas preferencialmente por meio de sondas enterais (KLEK *et al.*, 2014).

Cabe destacar que, por ser uma instituição de saúde pública, o sistema de compras de nutrição especial ocorre através de licitação, processo em que geralmente um pedido é estimado para ter duração de 15 meses. Nesta estimativa, são utilizadas médias históricas como forma de previsão de demanda sem processo formal ou modelos matemáticos, ficando dependente da experiência dos funcionários envolvidos. Observa-se assim, oportunidades de melhoria para o setor em estudo.

Em relação à coleta de dados, foram utilizados os registros de consumo diários, os quais apresentam a quantidade e frequência de consumo de produtos prescritos a cada paciente, os quais foram compilados manualmente. Os valores de demanda foram divididos em 4 famílias: mamadeiras, seringas, suplementos e enterais (as duas primeiras utilizadas para entrega de fórmulas infantis). As informações obtidas compreendem dados disponíveis de 22 meses de demanda, onde 18 meses são utilizados como treino do modelo e 4 meses utilizados para teste de acurácia por meio do MAPE. Paralelamente, foram coletados dados adicionais com intuito

de conhecer os processos e capturar outras informações a partir da realização de entrevistas semiestruturadas e por meio de observação participativa.

A partir dos dados compilados, os modelos de previsão de demanda foram gerados e testados para cada família com base nos métodos levantados (ARIMA, suavização exponencial, médias móveis, regressão linear e redes neurais artificiais). O que se busca nesta etapa é descobrir qual das versões dos modelos melhor descreve o comportamento dos dados investigados. Inicialmente, para o desenvolvimento do modelo baseado na técnica de ARIMA, foi utilizada a opção '*Expert Modeler*' do *software*, a qual identifica os melhores coeficientes do modelo na estrutura: (AR, I, MA). Semelhantemente, para o método de suavização exponencial, a mesma função foi utilizada para indicar o modelo de maior acuracidade para cada família (Aditivo de Winters, Multiplicativo de Winters, Holt, Brown, Tendência Amortecida, Sazonal Simples, etc). Já no método de médias móveis, as estimativas de previsão foram geradas a partir da média dos quatro meses antecedentes. Para a família mamadeiras, o *software* indicou ARIMA (1, 0, 1) e “sazonal simples” para Suavização Exponencial como melhores opções de modelos. Para a família de seringas: ARIMA (1, 0, 0) e Aditivo de Winters. Em relação à família enterais: ARIMA (1, 1, 1) e Aditivo de Winters. Finalmente para a família suplementos: ARIMA (1, 1, 0) e Aditivo de Winters.

A partir das entrevistas semiestruturadas definiu-se as variáveis independentes que participarão dos modelos de regressão linear e redes neurais para cada família. Os especialistas mencionaram que a variável “pacientes-dia mensal” de cada unidade de internação hospitalar é a variável mais utilizada para fins de planejamento e com maior afinidade com a demanda de nutrição especial. Pacientes-dia mensal corresponde ao somatório do número de pacientes internados (dia a dia) no período de um mês (MIN; SCOTT, 2016). Para a família de suplementos, notou-se que 95% dos materiais destinam-se para as seguintes unidades de internação: Clínica Médica (CM), Clínica Cirúrgica (CC) e UTI (Unidade de Terapia Intensiva). Portanto, a variável a ser testada para prever a demanda desta família será a soma do número de pacientes-dia mensal dessas três unidades de internação. Para a família de enterais, observou-se que 99% dos materiais são destinados para CC, CM e UTI, portanto a variável a ser testada será a mesma da família de suplementos. Verificou-se para a família de Mamadeiras que 100% dos materiais são destinados para a Unidade de Internação Pediátrica (UIP), assim a variável independente a ser testada será o número de pacientes-dia mensal desta unidade de internação. Por fim, para a família de Seringas, observou-se que 99% do destino das seringas é para a

Unidade de UTI neonatal (UTI-Neo), portanto a variável a ser testada será o número de pacientes-dia mensal da Unidade de UTI-Neo.

A Tabela 1 apresenta os resultados das análises estatísticas geradas na comparação entre modelos. A análise foi realizada com base em duas variáveis estatísticas,  $R^2$  e MAPE. O  $R^2$  é um dos indicadores mais aplicados em testes estatísticos, sendo que quanto mais próximo o valor de 1, mais preciso é o modelo (PLONSKY; GHANBAR, 2018).

Tabela 1 - Comparação entre modelos Tabela 1 - Comparação entre modelos

		ARIMA	SE <sup>a</sup>	MM <sup>b</sup>	RL <sup>c</sup>	RNA <sup>d</sup>
Mamadeiras	R <sup>2</sup>	0,103	0,688	-	0,829	-
	MAPE	19,2%	15,4%	15,5%	7,29%	10,8%
Seringas	R <sup>2</sup>	0,319	0,790	-	0,661	-
	MAPE	28,5%	25,6%	33,7%	12,81%	32%
Suplementos	R <sup>2</sup>	0,725	0,944	-	0,717	-
	MAPE	5,4%	6,4%	8,5%	11,6%	12,7%
Enterais	R <sup>2</sup>	0,333	0,191	-	0,586	-
	MAPE	6,0%	10,1%	8,9%	7,08%	14,1%

<sup>a</sup>SE - suavização exponencial; <sup>b</sup>MM médias móveis; <sup>c</sup>regressão linear; <sup>d</sup>redes neurais artificiais

Fonte: Elaborado pelos autores

Os resultados sugerem que tanto para mamadeiras quanto para seringas, os modelos de maior acurácia são gerados a partir do método de regressão linear, o qual apresentou um  $R^2$  de 0,829, para mamadeiras e, 0,661 para seringas, além de um valor de MAPE correspondente a 7,29% e 12,81%, respectivamente. Tendo em vista que a regressão linear apresentou melhor desempenho nos dois indicadores mensurados, o modelo gerado foi considerado ideal para sua utilização. Este resultado pode estar relacionado ao fato dessas duas famílias de produtos dependerem unicamente de uma variável preditora a qual afeta a demanda de mamadeiras na UIP e seringas na UTI neonatal. Particularmente, os métodos envolvendo regressão linear, destacam-se dentre os modelos causais, pois fornecem resultados razoavelmente precisos, são fáceis de interpretar e têm amplas aplicações na modelagem (SOYIRI; REIDPATH, 2013).

No entanto, nas famílias de enterais e suplementos, os resultados demonstraram que existem métodos com maior acurácia como o caso do ARIMA. Para ambos os produtos, a aplicação da regressão simples compreendeu a utilização de uma variável preditora que corresponde à soma

de três variáveis. Esta soma pode gerar erros grandes já que muitas vezes não é linear a relação entre variável dependente e independente em muitas séries de dados, além de que outros fatores podem estar influenciando na demanda. Em função disso, os valores estimados para esses três componentes devem ter reduzido a acurácia dos modelos gerados. Conforme sugerido por Jones *et al.* (2008), em caso de variáveis múltiplas, a regressão linear apresenta fraqueza e requer coleta de dados adicional e estimativa de parâmetros.

Dentre as técnicas utilizadas, o método ARIMA foi considerado o mais indicado para estimar a demanda de suplementos e enterais, uma vez que o valor de  $R^2$  obtido foi de 0,725 para suplementos e, 0,333 para enterais, além de um valor de MAPE correspondente a 5,40% e 6,00%, respectivamente. Cabe destacar que nas duas famílias, os resultados obtidos na análise demonstraram uma tendência de dados estável, corroborando com a pesquisa de previsão de dispositivos médicos realizada por Xu *et al.* (2020), a qual defende o método ARIMA como o mais adequado para séries temporais com dados estacionários. O estudo de Kim *et al.* (2014) apresentou o ARIMA como a melhor técnica para previsão de entrada de pacientes.

A partir da definição de qual método apresenta uma melhor previsão de demanda para cada família, é possível efetuar o processo de compra de materiais de forma mais assertiva, além de calcular o estoque ideal otimizando o custo de estoque do hospital em estudo. O preço e a acessibilidade dos suprimentos hospitalares sempre foram uma grande preocupação já que impactam significativamente no orçamento das organizações de saúde. O custo da cadeia de suprimentos do setor de saúde é de cerca de 30–45% (XU *et al.* 2020) em contraste com o setor de varejo com 5% e o setor de eletrônicos que pode chegar a 2%. Dessa forma, é de suma importância a redução dos custos de estoque em hospitais, utilizando para isso técnicas estruturadas de previsão de demanda.

## 5. Conclusão

O presente estudo teve como objetivo comparar diferentes modelos de previsão de demanda das famílias de materiais de nutrição especial em um hospital público. A partir do trabalho desenvolvido, destacam-se contribuições teóricas e práticas. Em termos teóricos, este trabalho complementa o corpo de literatura da área ao investigar diferentes modelos de previsão de demanda para materiais de nutrição especial. No que diz respeito à aplicação em termos práticos, o trabalho apresenta diretrizes para incorporar métodos de planejamento e controle de materiais de nutrição especial de forma financeira e operacional.



Nas análises realizadas, foram comparados os resultados provenientes de cinco métodos estatísticos para previsão de demanda, a citar: ARIMA, suavização exponencial, média móvel, regressão linear e redes neurais artificiais. Os resultados demonstraram que a regressão linear se enquadrou de forma mais assertiva para representar o consumo de materiais cuja demanda era dependente de uma única variável, como é o caso das mamadeiras e seringas, as quais têm seu volume de consumo alterado linearmente em função da quantidade de pacientes na UIP e UTI-neo, respectivamente. Já em situações em que se dependia da estimação da soma de mais de uma variável, as análises demonstraram que o método ARIMA foi considerado o mais indicado para estimar a demanda destes produtos.

Cabe ainda destacar algumas limitações da pesquisa. Optou-se pela escolha de um setor específico de uma única organização de saúde para realizar a investigação pretendida. Contudo, deve-se salientar a necessidade de outras pesquisas de modo a averiguar se os mesmos resultados alcançados no presente trabalho se aplicam ao departamento de nutrição de outras instituições de saúde. Além disso, o trabalho está limitado à disponibilidade de dados fornecidos pela organização de saúde, os quais foram obtidos por procedimentos manuais, ocasionando grande perda das informações. Estudos que envolvam dados mais precisos e com histórico mais amplo poderiam contribuir com um método de previsão de demanda de materiais mais robusto. Adicionalmente, outras variáveis poderiam ser testadas nos modelos, tais como tipos de doenças, idade, estado nutricional do paciente, cirurgias. O acréscimo de tais variáveis poderia permitir um melhor refinamento dos modelos alcançados.

## Referências

ARIMIE, Christopher O.; BIU, Emmanuel O.; IJOMAH, Maxwell A. Forecasting diagnostic imaging utilisation rate for effective healthcare delivery. **African Journal of Economic and Sustainable Development**, v. 7, n. 1, p. 73-87, 2018.

BAIHAQI, Wiga Maulana et al. Linear Regression Method to Model and Forecast the Number of Patient Visits in the Hospital. In: **2018 3rd International Conference on Information Technology, Information System and Electrical Engineering (ICITISEE)**. IEEE, 2018. p. 247-252.

BALCÁZAR-CAMACHO, Delio Alexander; LÓPEZ-BELLO, Cesar Amílcar; ADARME-JAIMES, Wilson. Strategic guidelines for supply chain coordination in healthcare and a mathematical model as a proposed mechanism for the measurement of coordination effects. **Dyna**, v. 83, n. 197, p. 203-211, 2016.

CALLENDER, Carlos; GRASMAN, Scott E. Barriers and best practices for material management in the healthcare sector. **Engineering Management Journal**, v. 22, n. 4, p. 11-19, 2010.

CHENG, Chen-Yang; CHIANG, Kuo-Liang; CHEN, Meng-Yin. Intermittent Demand Forecasting in a Tertiary Pediatric Intensive Care Unit. **Journal of Medical Systems**, v. 40, n. 10, p. 217, 2016.

CORREIA, Maria Fernanda Zelaya; CRUZ, Luis Gustavo Zelaya; DA SILVA, Patricia Furtado. Principais desafios no suprimento para unidades hospitalares—uma abordagem com mapeamento de processos para análise de critérios de compra de materiais cirúrgicos. **Brazilian Journal of Business**, v. 2, n. 3, p. 2272-2288, 2020.

EARNEST, Arul et al. Using autoregressive integrated moving average (ARIMA) models to predict and monitor the number of beds occupied during a SARS outbreak in a tertiary hospital in Singapore. **BMC Health Services Research**, v. 5, n. 1, p. 36, 2005.

FORTSCH, Sima M.; KHAPALOVA, Elena A. Reducing uncertainty in demand for blood. **Operations Research for Health Care**, v. 9, p. 16-28, 2016.

GELPER, Sarah; FRIED, Roland; CROUX, Christophe. Robust forecasting with exponential and Holt–Winters smoothing. **Journal of forecasting**, v. 29, n. 3, p. 285-300, 2010.

GOODWIN, Paul et al. The process of using a forecasting support system. **International Journal of Forecasting**, v. 23, n. 3, p. 391-404, 2007.

GUL, Muhammet; CELIK, Erkan. An exhaustive review and analysis on applications of statistical forecasting in hospital emergency departments. **Health Systems**, v. 9, n. 4, p. 263-284, 2020.

JOHNSTON, F. R. et al. Some properties of a simple moving average when applied to forecasting a time series. **Journal of the Operational Research Society**, v. 50, n. 12, p. 1267-1271, 1999.

JONES, Spencer S. et al. Forecasting daily patient volumes in the emergency department. **Academic Emergency Medicine**, v. 15, n. 2, p. 159-170, 2008.

KALPAKIS, Konstantinos; GADA, Dhiral; PUTTAGUNTA, Vasundhara. Distance measures for effective clustering of ARIMA time-series. In: **Proceedings 2001 IEEE international conference on data mining**. IEEE, 2001. p. 273-280.

KIM, Sungil; KIM, Heeyoung. A new metric of absolute percentage error for intermittent demand forecasts. **International Journal of Forecasting**, v. 32, n. 3, p. 669-679, 2016.

KIM, Kibaek et al. Predicting patient volumes in hospital medicine: A comparative study of different time series forecasting methods. **Northwestern University, Illinois, USA, Scientific Report**, 2014.

KLEK, Stanislaw et al. Home enteral nutrition reduces complications, length of stay, and health care costs: results from a multicenter study. **The American Journal of Clinical Nutrition**, v. 100, n. 2, p. 609-615, 2014.

KUMAR, Dinesh; KUMAR, Dinesh. Modelling hospital inventory management using interpretive structural modelling approach. **International Journal of Logistics Systems and Management**, v. 21, n. 3, p. 319-334, 2015.

LALIS, Jeremias T. A new multiclass classification method for objects with geometric attributes using simple linear regression. **IAENG International Journal of Computer Science**, v. 43, n. 2, p. 198-203, 2016.

MARCILIO, I.; HAJAT, S.; GOUVEIA, N. Previsão de visitas diárias ao departamento de emergência usando variáveis de calendário e leituras de temperatura ambiente. **Medicina de Emergência Acadêmica**, v. 20, n. 8, p. 769-777, 2013.

MIN, Ari; SCOTT, Linda D. Evaluating nursing hours per patient day as a nurse staffing measure. **Journal of Nursing Management**, v. 24, n. 4, p. 439-448, 2016.

CHAWLA, Aditya et al. Demand forecasting using artificial neural networks—a case study of American retail corporation. In: **Applications of Artificial Intelligence Techniques in Engineering**. Springer, Singapore, p. 79-89, 2019.

MOONS, Karen; WAEYENBERGH, Geert; PINTELON, Liliane. Measuring the logistics performance of internal hospital supply chains—a literature study. **Omega**, v. 82, p. 205-217, 2019.

ORDU, Muhammed; DEMIR, Eren; TOFALLIS, Chris. A comprehensive modelling framework to forecast the demand for all hospital services. **The International Journal of Health Planning and Management**, v.34, n.2, p. e1257-e1271, 2019.

PLONSKY, Luke; GHANBAR, Hessameddin. Multiple regression in L2 research: A methodological synthesis and guide to interpreting R2 values. **The Modern Language Journal**, v. 102, n. 4, p. 713-731, 2018.

REN, Shuyun; CHAN, Hau-Ling; SIQIN, Tana. Demand forecasting in retail operations for fashionable products: methods, practices, and real case study. **Annals of Operations Research**, v. 291, n. 1, p. 761-777, 2020.

RISTANOSKI, Goce; LIU, Wei; BAILEY, James. Time series forecasting using distribution enhanced linear regression. In: **Pacific-Asia Conference on Knowledge Discovery and Data Mining**. Springer, Berlin, Heidelberg, 2013. p. 484-495.

SETYANINGSIH, Santi; BASRI, Mursyid Hasan. The Evaluation of Forecasting Method for Enteral and Formula Food Supply to Support Inventory Management System Hospital. **Management**, v. 3, n. 2, p. 121-127, 2013.

SOYIRI, Ireneous N.; REIDPATH, Daniel D. An overview of health forecasting. **Environmental Health and Preventive Medicine**, v. 18, n. 1, p. 1-9, 2013.

WARGON, M. et al. A systematic review of models for forecasting the number of emergency department visits. **Emergency Medicine Journal**, v. 26, n. 6, p. 395-399, 2009.

XU, Shuojiang et al. A comparison of forecasting methods for medical device demand using trend-based clustering scheme. **Journal of Data, Information and Management**, p. 1-10, 2020.

YERPUDE, Samir; SINGHAL, Tarun Kumar. Impact of internet of things (IoT) data on demand forecasting. **Indian Journal of Science and Technology**, v. 10, n. 15, p. 1-5, 2017.