

Gestão de Demandas de Serviços de Software para Provedores com Suporte de Machine Learning e Dinâmica de Sistemas

Ednardo da Rocha¹, Alberto Sampaio Lima¹,
José Neuman de Souza², José Antônio Beltrão Moura³

¹Departamento de Engenharia de Teleinformática
Universidade Federal do Ceará (UFC)
Fortaleza, CE – Brazil

ednardorochal@gmail.com, albertosampaio@ufc.br

²Departamento de Computação (DC)
Universidade Federal do Ceará (UFC)
Fortaleza, CE – Brazil

neuman@ufc.br

³Departamento de Sistemas e Computação
Universidade Federal de Campina Grande (UFCG)
Campina Grande, PB – Brazil

antao@dsc.ufcg.edu.br

Abstract. *Demand management in software services provided by vendors faces challenges such as the unpredictability of request arrivals and the need to maintain strict service level agreements (SLAs). This article proposes a hybrid model that integrates System Dynamics (SD) and Machine Learning (ML) to forecast demand and simulate the evolution of the service backlog. The algorithms Random Forest, MLP, and Gradient Boosting were evaluated, with Random Forest demonstrating the lowest predictive error. The results show that the proposed model enables the analysis of operational scenarios based on historical data, anticipates bottlenecks, and supports decision-making regarding resource allocation. Its modular and reproducible structure makes the solution applicable to real-world service management contexts, fostering proactive and evidence-based actions.*

Resumo. *A gestão de demandas em serviços de software de provedores enfrenta desafios como a imprevisibilidade na chegada de solicitações e a necessidade de manter níveis rigorosos de serviço (SLA). Este artigo propõe um modelo híbrido que integra Dinâmica de Sistemas (DS) e Aprendizado de Máquina (ML) para prever a demanda e simular a evolução do backlog de atendimento. Foram avaliados os algoritmos Random Forest, MLP e Gradient Boosting, sendo o Random Forest o que apresentou menor erro preditivo. Os resultados mostram que o modelo proposto permite analisar cenários operacionais com base em dados históricos, antecipar gargalos e apoiar decisões sobre alocação de recursos. A estrutura modular e reprodutível torna a solução aplicável em contextos reais de gestão de serviços, promovendo uma atuação proativa e baseada em evidências.*

1. Introdução

Modelos tradicionais, baseados em estimativas fixas e cronogramas rígidos, mostram-se limitados diante da volatilidade dos requisitos de negócio [Kohlrausch 2013], reforçando

a necessidade de abordagens mais flexíveis para antecipar padrões e ajustar a alocação de recursos, evitando acúmulo de *backlog*.

Embora metodologias ágeis e práticas de governança de TI tenham evoluído, ainda faltam soluções que unam previsão proativa e resposta sistêmica. O uso de *Machine Learning (ML)* na previsão de cargas de trabalho e apoio à decisão tem se mostrado promissor [Polo-Triana et al. 2024], mas sua integração com Dinâmica de Sistemas (DS) na engenharia de *software* permanece incipiente. Estudos em outras áreas, como *supply chain* e operações [Akbari and Do 2021, Perea et al. 2000], destacam esse potencial, evidenciando a importância da integração de técnicas preditivas com modelagem dinâmica.

A variabilidade diária de solicitações, com média de 6,6 tickets e máximos de até 18 tickets por dia, como o aqui nesse estudo apresentado, reforça a necessidade de modelos preditivos mais robustos e que tragam alternativas de aplicação diferentes.

Este artigo propõe um modelo híbrido que combina ML e DS para apoiar a gestão de demandas, simulando a evolução do *backlog* a partir de variáveis como tempo de atendimento, capacidade e cumprimento de SLA. A estrutura modular permite antecipar gargalos, avaliar estratégias de alocação de recursos e aprimorar decisões com base em dados reais ou sintéticos. A integração já explorada em áreas como infraestrutura e manufatura [Li et al. 2020, Fenner et al. 2020] mostra-se igualmente promissora para a gestão de serviços de TI.

2. Fundamentação Teórica e Trabalhos Relacionados

2.1. Dinâmica de Sistemas

A Dinâmica de Sistemas (DS), desenvolvida por Forrester nos anos 1950, modela o comportamento de sistemas complexos por meio da interação entre estoques, fluxos e feedbacks [Villate 2016, Monteiro 2002]. [Chen et al. 2020] aplicou DS no planejamento de capacidade para a indústria. Em TI, a DS possibilita representar *backlog*, capacidade produtiva e impacto de decisões sobre SLAs e eficiência [Faezipour and Ferreira 2016, Choi et al. 2020]. Estudos recentes exploraram DS na gestão de serviços, como decisões de sourcing [Bezerra et al. 2024] e alocação de recursos em provedores de infraestrutura como serviço (*IaaS*) [Fenner et al. 2020]. Neste trabalho, a DS constitui a base estrutural para simular a evolução do *backlog* e seus efeitos sobre o nível de serviço.

2.2. Machine Learning

O Aprendizado de Máquina (ML) é amplamente usado para extrair padrões e apoiar decisões em ambientes complexos [Akbari and Do 2021, Ye et al. 2018]. Em gestão de incidentes, técnicas como Random Forest, SVMs e redes neurais auxiliam na priorização e encaminhamento de *tickets* [Polo-Triana et al. 2024]. Aqui, o ML é o componente preditivo do modelo híbrido, responsável por antecipar a chegada de demandas e alimentar o simulador dinâmico.

2.3. Gestão de Demandas em Provedores de Serviço

A gestão de demandas envolve controlar e priorizar solicitações, garantindo eficiência e qualidade [Beal 2001]. O aumento da complexidade exige ferramentas automatizadas e flexíveis [Polo-Triana et al. 2024]. No modelo proposto, a DS representa a dinâmica operacional, enquanto o ML fornece previsões, permitindo avaliar políticas de resposta e apoiar decisões de forma mais assertiva.

3. Metodologia

O modelo híbrido combina *Machine Learning* (ML) e Dinâmica de Sistemas (DS) para analisar e simular a evolução do *backlog* em equipes de TI. Dados históricos de tickets passam por pré-processamento, treinamento e validação de modelos preditivos de ML, cujas previsões alimentam o simulador dinâmico.

3.1. Modelagem Preditiva com Machine Learning

Foram utilizados três algoritmos de regressão: *Random Forest*, *Gradient Boosting* e *MLP*. A base de dados consistiu em 7.230 *tickets* coletados entre 2019 e 2023, com média de 6,6 *tickets*/dia (DP = 3,1) e máximo diário de 18 *tickets*. O particionamento dos dados seguiu a proporção 80% para treino (2019–2022) e 20% para teste (2023).

No pré-processamento, foram tratados valores ausentes, codificadas variáveis categóricas e normalizados apenas os dados de treino, evitando *data leakage*. A avaliação dos modelos considerou MSE e MAE. O desenvolvimento foi realizado em *Python 3.10*, utilizando as bibliotecas *pandas*, *scikit-learn*, *numpy* e *matplotlib*.

3.2. Simulador Dinâmico com Dinâmica de Sistemas

A evolução do *backlog* foi modelada por equações de diferenças discretas, considerando demanda diária e capacidade de atendimento. A capacidade total de atendimento é definida como o produto do número de técnicos pelo número médio de *tickets* resolvidos por técnico por dia:

$$Capacidade = n \cdot Eficiência$$

sendo n o número de técnicos e *Eficiência* a média diária de *tickets* resolvidos por técnico.

O modelo conceitual considera estoques (*backlog*), fluxos (atendimento diário) e laços de retroalimentação. O SLA, definido como percentual de *tickets* resolvidos dentro do prazo, é uma variável crítica: quanto maior o *backlog*, maior o risco de violação, impactando diretamente a qualidade do serviço. O simulador também incorpora políticas de ajuste dinâmico da capacidade, como aumento temporário de técnicos ou uso de automação, ampliando o realismo dos cenários.

3.3. Integração e Reprodutibilidade

As previsões de demanda geradas pelos modelos de ML foram integradas ao simulador dinâmico. Os parâmetros adotados incluem *backlog* inicial igual a zero, cinco técnicos, eficiência média de 2 *tickets*/dia por técnico (capacidade total de 10 *tickets*/dia) e horizonte de simulação de 30 dias.

A arquitetura é modular e replicável, permitindo a inclusão de novas variáveis, diferentes políticas de atendimento e aplicação em variados contextos organizacionais.

4. Resultados e Discussão

Foram avaliados três modelos de aprendizado de máquina — *MLP*, *Gradient Boosting* e *Random Forest* — aplicados à previsão de demanda de *tickets*. As previsões alimentaram um simulador dinâmico com capacidade fixa de 10 *tickets*/dia, permitindo analisar o impacto no *backlog*.

4.1. Métricas de Avaliação Quantitativa e Comparativa

O *Random Forest* apresentou os menores erros de previsão, seguido pelo *MLP*, enquanto o *Gradient Boosting* mostrou maior erro, indicando menor capacidade de generalização. Na simulação do *backlog*, o modelo híbrido (ML + DS) reproduziu padrões sazonais e picos de demanda com maior precisão, enquanto o DS simples apresentou crescimento quase linear, distanciando-se dos dados reais. Assim, a combinação de ML e DS demonstrou superioridade tanto nas métricas quantitativas quanto na simulação de *backlog*.

4.2. Análise Dinâmica dos Resultados

As figuras abaixo apresentam os resultados de forma consolidada.




Figura 1. À esquerda: simulação do *backlog* acumulado em 2023 para diferentes modelos preditivos, evidenciando que *Random Forest* reproduz trajetórias mais próximas do comportamento real, enquanto *MLP* e *Gradient Boosting* tendem a superestimar a demanda. À direita: demanda real vs previsão *Random Forest* por trimestre (2023), mostrando boa aderência aos padrões de variação.

O painel demonstra que, mesmo diante de ruídos nos dados, a natureza *ensemble* do *Random Forest* favoreceu a captura de padrões consistentes, especialmente em cenários com sazonalidade. A validação combinou métricas quantitativas (MSE e MAE) e simulação do *backlog* em cenários fixos (capacidade de 10 *tickets*/dia e horizonte de 30 dias), garantindo robustez na comparação.

4.3. Implicações para a Gestão de Demandas

Os resultados reforçam que abordagens preditivas superam estratégias baseadas em médias históricas, que não capturam variações temporais. A arquitetura híbrida fornece suporte à decisão em ajustes de capacidade e redistribuição de técnicos, permitindo prever gargalos e orientar decisões de gestão de forma mais eficaz.

5. Conclusões

Este artigo apresentou um modelo híbrido que integra Aprendizado de Máquina (ML) e Dinâmica de Sistemas (DS) para apoiar a gestão de demandas em serviços de *software*. A abordagem permite prever a chegada de solicitações e simular o comportamento do *backlog* considerando a capacidade operacional.

Os experimentos mostraram que modelos de ML, em especial o *Random Forest*, apresentaram maior aderência ao comportamento real do *backlog*, superando métodos baseados em médias históricas. A integração com DS possibilitou antecipar gargalos, avaliar impactos no SLA e planejar a capacidade de forma mais assertiva.

Do ponto de vista gerencial, o modelo fornece suporte prático para redistribuição de técnicos, ajustes de turnos e definição de políticas preventivas, promovendo uma gestão

mais proativa e baseada em evidências. Ao permitir a simulação de cenários futuros com base em previsões confiáveis, amplia-se a previsibilidade operacional e a qualidade do serviço.

Como trabalho futuro, pretende-se incorporar critérios de priorização, SLAs diferenciados e dados reais de plataformas de atendimento, ampliando a aplicabilidade do modelo em contextos organizacionais diversos.

Referências

- Akbari, M. and Do, T. N. A. (2021). A systematic review of machine learning in logistics and supply chain management: current trends and future directions. *Benchmarking: An International Journal*, 28(10):2977–3005.
- Beal, A. (2001). Introdução à gestão de tecnologia da informação. *Beal Educação e Tecnologia*, 2.
- Bezerra, T. R., Moura, J. A. B., Lima, A. S., and Souza, J. N. d. (2024). Decision-making support in it services sourcing management through a system dynamics model. *IEEE Transactions on Network and Service Management*, 21(4):3813–3828.
- Chen, S., Pan, Y., Chen, L., and Wu, D. D. (2020). A system dynamics model for capacity planning of component supply in complex product manufacturing. *IEEE Systems Journal*, 15(1):8–16.
- Choi, J.-h., Lee, Y., and Kwak, Y. H. (2020). A socioeconomic ripple effect analysis of integrative national construction standards codification efforts: system dynamics approach. *IEEE Transactions on Engineering Management*, 69(6):2959–2975.
- Faezipour, M. and Ferreira, S. (2016). A system dynamics approach for sustainable water management in hospitals. *IEEE Systems Journal*, 12(2):1278–1285.
- Fenner, G., Lima, A. S., Souza, J. N. d., Moura, J. A. B., and Bezerra, T. R. (2020). Business-driven support for infrastructure as a service capacity management through system dynamics simulations. *IEEE Transactions on Network and Service Management*, 18(2):2063–2076.
- Kohlrausch, G. S. (2013). Proposta para implantação e gestão de um processo de desenvolvimento de software baseado em métodos ágeis. Master's thesis, Universidade do Vale do Rio dos Sinos (UNISINOS).
- Li, X., Kuang, H., and Hu, Y. (2020). Using system dynamics and game model to estimate optimal subsidy in shore power technology. *IEEE Access*, 8:116310–116320.
- Monteiro, L. H. A. (2002). *Sistemas dinâmicos*. Editora Livraria da Física.
- Perea, E., Grossmann, I., Ydstie, E., and Tahmassebi, T. (2000). Dynamic modeling and classical control theory for supply chain management. *Computers & Chemical Engineering*, 24(2-7):1143–1149.
- Polo-Triana, S., Gutierrez, J. C., and Leon-Becerra, J. (2024). Integration of machine learning in the supply chain for decision making: A systematic literature review. *Journal of Industrial Engineering and Management*, 17(2):344–372.
- Villate, J. E. (2016). *Dinâmica e sistemas dinâmicos*. Universidade do Porto, Creative Commons Attribution Sharealike, ISBN 978-972-99396-1-7.
- Ye, H., Liang, L., Li, G. Y., Kim, J., Lu, L., and Wu, M. (2018). Machine learning for vehicular networks: Recent advances and application examples. *IEEE Vehicular Technology Magazine*, 13(2):94–101.