

Vandirleya Barbosa da Costa
Orientador: Francisco Airton Pereira da Silva

Avaliação de Desempenho de um Aviário Inteligente com Arquitetura Edge-Fog-Cloud

Picos - PI
30 de junho de 2025

Vandirleya Barbosa da Costa
Orientador: Francisco Airton Pereira da Silva

Avaliação de Desempenho de um Aviário Inteligente com Arquitetura Edge-Fog-Cloud

Modelo de Trabalho de Conclusão de Curso
em Bacharelado em Sistemas de Informação
na Universidade Federal do Piauí. Este mo-
delo está em conformidade com as normas
ABNT.

Universidade Federal do Piauí
Campus Senador Heuvídio Nunes de Barros
Bacharelado em Sistemas de Informação

Picos - PI
30 de junho de 2025

FICHA CATALOGRÁFICA
Serviço de Processamento Técnico da Universidade Federal do Piauí
Biblioteca José Albano de Macêdo

C837a Costa, Vandırleya Barbosa da.

Avaliação de desempenho de uma viário inteligente com arquitetura
Edge-Fog-Cloud / Vandırleya Barbosa da Costa – 2025.
44 f.

1 Arquivo em PDF

Indexado no catálogo *online* da biblioteca José Albano de Macêdo-CSHNB
Aberto a pesquisadores, com restrições da Biblioteca

Trabalho de Conclusão de Curso (Graduação) – Universidade Federal do
Piauí, Curso de Bacharelado em Sistemas de Informação, Picos, 2025.
“Orientador: Francisco Airton Pereira da Silva”

1. Desempenho de sistemas. 2. Internet das coisas. 3. Redes de Petri. I.
Costa, Vandırleya Barbosa da. II. Silva, Francisco Airton Pereira da. III. Título.

CDD 005.7

Elaborada por Maria Letícia Cristina Alcântara Gomes
Bibliotecária CRB nº 03/1835

AVALIAÇÃO DE DESEMPENHO DE UM AVIÁRIO INTELIGENTE COM
ARQUITETURA EDGE-FOG-CLOUD

VANDIRLEYA BARBOSA DA COSTA

Monografia aprovada como exigência parcial para obtenção do grau de Bacharel em Sistemas
de Informação.

Data de Aprovação

Picos – PI, 25 de junho de 2025

Documento assinado digitalmente
 FRANCISCO AIRTON PEREIRA DA SILVA
Data: 23/06/2025 11:35:13-0300
Verifique em <https://validar.iti.gov.br>

Prof. Francisco Ailton Pereira da Silva

Documento assinado digitalmente
 IURE DE SOUSA FÉ
Data: 25/06/2025 20:28:40-0300
Verifique em <https://validar.iti.gov.br>

Prof. Íure de Sousa Fé

Documento assinado digitalmente
 FREDISON MUNIZ DE SOUSA
Data: 26/06/2025 18:37:39-0300
Verifique em <https://validar.iti.gov.br>

Prof. Fredison Muniz de Sousa

Agradecimentos

Primeiramente, gostaria de agradecer a Deus, por me conceder força e perseverança para me manter no caminho e continuar, independentemente de todas as adversidades.

Agradeço também à minha família, em especial à minha mãe Valmira e aos meus irmãos Jordanael e Natanael, por sempre me incentivarem e me apoiarem, mesmo sem entender exatamente com o que eu estava estudando, e por serem o meu maior motivo para buscar sempre o melhor de mim. Agradeço também aos meus avós, Inácio Verício e Lucina, por todo o carinho e incentivo depositados ao longo dessa jornada. E à minha sobrinha Cecília, por me ensinar um novo significado do que é amor e por iluminar nossas vidas de uma maneira maravilhosa.

Aos meus amigos Viviane e Adriano, só tenho a agradecer por estarem comigo desde o começo, por todo o incentivo, por nunca me deixarem desistir e por serem a luz que eu precisava quando o mundo parecia escuro demais. Sou imensamente grata por ter vocês na minha vida. À minha amiga Dara, obrigada por me acolher quando eu mais precisei e por ser uma amiga incrível. Quero agradecer também aos meus amigos Luiz Nelson e Arthur, por todos os momentos que passamos juntos, pelo acolhimento e pela nossa união durante todas as dificuldades acadêmicas. Obrigada por serem minha segunda família. Aos meus amigos Marcos, Mislaine, Melissa, Davi, Dalessandro, e a todos os outros que, de alguma forma, foram importantes na minha vida, obrigada por tornarem a vida acadêmica mais tolerável e divertida.

Ao professor e meu orientador, Dr. Francisco Airton Silva, deixo minha mais profunda gratidão. Quando eu não tinha sequer um celular para acompanhar as aulas e seguir com os estudos, o senhor acreditou em mim. Me acolheu mesmo quando eu só tinha a vontade de aprender e seguir em frente. Me emprestou não só um notebook, mas também confiança, conhecimento, apoio e a oportunidade de participar do seu grupo de pesquisa.

Aos amigos que o PASID me deu — Leonel, Carlos, Iure e os demais —, obrigado por contribuírem com minha jornada acadêmica. É uma honra trabalhar com vocês. Quero deixar também meus agradecimentos aos professores do curso de Sistemas de Informação, pela dedicação e por não medirem esforços para compartilhar conhecimento. Ao professor e atual coordenador do curso, Dr. Frank César, muito obrigada por sempre ter feito o possível para me ajudar. Cada memorando de acesso ao laboratório do curso me deu ânimo e esperança de que dias melhores viriam.

Em suma, sou grata a todos vocês. O gesto de cada um mudou o rumo da minha caminhada acadêmica e pessoal. Nunca vou esquecer disso. Muito obrigada, de coração.

Se não existe outra vida, então é preciso construí-la a partir desses escombros.
Fiódor Dostoiévski

Resumo

A Internet das Coisas (IoT) tem transformado ambientes industriais ao possibilitar a automação de processos e a melhoria dos sistemas de apoio à decisão. No setor agrícola, essa tecnologia tem promovido ganhos significativos de produtividade e eficiência, especialmente em instalações como aviários, onde o controle ambiental é essencial. Os sensores monitoram variáveis críticas, como temperatura, umidade, gás e luz, viabilizando a coleta e análise de dados em tempo quase real. As tecnologias como Edge, Fog e Cloud Computing sustentam esse ecossistema, ao distribuir o processamento de dados entre diferentes camadas. Embora eficientes, essas soluções enfrentam desafios, como o alto volume de dados gerados e a necessidade de transferências rápidas e confiáveis. Os atrasos nesse fluxo comprometem o monitoramento contínuo e a tomada de decisão, afetando o desempenho da operação. Portanto, esta monografia propõe um modelo baseado em Redes de Petri Estocásticas (SPN) para avaliar o desempenho de sistemas industriais avícolas inteligentes. O modelo permite mensurar métricas como tempo médio de resposta (MRT), utilização de recursos, probabilidade de descarte de dados (DP) e vazão do sistema (TP). A flexibilidade do modelo permite a adaptação a diferentes cenários, facilitando ajustes conforme as demandas da aplicação. A proposta contribui para otimizar o uso da IoT na automação agrícola e ampliar sua aplicação de forma mais confiável e eficiente.

Palavras-chaves: Internet das Coisas, Edge, Fog, Cloud, Aviários Inteligentes, Redes de Petri, Desempenho de sistemas.

Abstract

The Internet of Things (IoT) has transformed industrial environments by enabling process automation and improving decision support systems. In the agricultural sector, this technology has led to significant gains in productivity and efficiency, especially in facilities such as poultry farms, where environmental control is essential. Sensors monitor critical variables such as temperature, humidity, gas, and light, enabling the collection and analysis of data in near real-time. Technologies such as Edge, Fog, and Cloud Computing support this ecosystem by distributing data processing across different layers. Although efficient, these solutions face challenges such as the high volume of generated data and the need for fast and reliable data transfers. Delays in this flow compromise continuous monitoring and decision-making, affecting operational performance. Therefore, this monograph proposes a model based on Stochastic Petri Nets (SPN) to evaluate the performance of intelligent industrial poultry systems. The model allows the measurement of metrics such as mean response time (MRT), resource utilization, drop probability (DP), and throughput (TP). The model's flexibility enables adaptation to different scenarios, facilitating adjustments according to application demands. The proposal contributes to optimizing the use of IoT in agricultural automation and expanding its application in a more reliable and efficient manner.

Keywords: Internet of Things, Edge-Fog-Cloud Computing, Smart Poultry Farms, Petri Nets, System Performance.

Lista de ilustrações

Figura 1 – Componentes SPNs.	16
Figura 2 – Arquitetura do Sistema do Aviário Inteligente.	21
Figura 3 – Fluxograma da arquitetura.	23
Figura 4 – Modelo SPN da Arquitetura Proposto.	24
Figura 5 – As partes que representam o Admission e a camada Edge.	25
Figura 6 – As partes que representam a camada Fog e a camada Cloud.	26
Figura 7 – Impacto da combinação de fatores na métrica MRT.	30
Figura 8 – Análise das interações entre fatores da Cloud e sua influência sobre a métrica MRT.	30
Figura 9 – Resultados da variação no número de cores de processamento na Cloud.	34
Figura 10 – Resultados da variação no tempo de serviço da Cloud.	36

Lista de tabelas

Tabela 1 – Trabalhos relacionados.	20
Tabela 2 – Componentes do modelo SPN	26
Tabela 3 – Fatores e níveis da simulação.	28
Tabela 4 – Combinações de níveis e fatores.	29
Tabela 5 – Valores atribuídos às transições e marcações do modelo SPN.	33
Tabela 6 – Valores utilizados no Cenário 1.	33
Tabela 7 – Valores utilizados no Cenário 2.	35

Lista de abreviaturas e siglas

AD	Atraso de Chegada
AR	Taxa de Chegada
CapC	Capacidade da Fila na Cloud
CapE	Capacidade da Fila na Edge
CapF	Capacidade da Fila na Fog
CapRC	Capacidade da Fila do Roteador da Cloud
CapRE	Capacidade da Fila do Roteador da Edge
CapRF	Capacidade da Fila do Roteador da Fog
Cloud	Cloud Computing
CPU	Unidade Central de Processamento
DP	Probabilidade de Descarte
DoE	Design of Experiments
Edge	Edge Computing
Fog	Fog Computing
IoT	Internet das Coisas
MRT	Tempo Médio de Resposta
NuC	Número de Recursos da Cloud
NuE	Número de Recursos da Edge
NuF	Número de Recursos da Fog
PN	Redes de Petri
SPN	Redes de Petri Estocástica
SSDA	Automação de Dados Auto-Sincronizados
ST_C	Tempo de Serviço na Cloud
TP	Throughput

Sumário

1	Introdução	12
1.1	Objetivos	13
2	Referencial Teórico	14
2.1	Aviários Inteligentes	14
2.2	Edge, Fog e Cloud Computing	14
2.3	Redes de Petri Estocásticas	15
2.4	Avaliação de Desempenho	16
2.5	Análise de Sensibilidade com DoE	16
3	Trabalhos Relacionados	18
3.1	Trabalhos Baseados em Mensuração	18
3.2	Trabalhos Baseados em Simulação	19
3.3	Contribuições Desta Monografia	19
4	Arquitetura	21
5	Modelo SPN	23
5.1	Modelagem da Arquitetura	24
5.2	Métricas	26
6	Design of Experiments	28
6.1	Análise de Sensibilidade Utilizando DoE	28
6.2	Resultados do DoE	28
7	Casos de Estudo	32
7.1	Cenário 1 - Variação no Número de Cores de Processamento na Cloud	33
7.2	Cenário 2 - Variação no Tempo de Processamento na Cloud	35
8	Conclusão	37
9	Publicações	38
	Referências	41

1 Introdução

A indústria avícola desempenha um papel crucial na produção em larga escala de carne e ovos, atendendo à crescente demanda global por alimentos de origem animal. Até 2027, estima-se que o mercado global de carne de aves atinja US\$ 487,39 bilhões (ASSESSMENT... , 2023). Já o mercado global de ovos, avaliado em US\$ 150,83 bilhões em 2024, apresenta projeção de crescimento para US\$ 222,86 bilhões até 2032 (EGGS... , 2024). Atualmente, a avicultura brasileira é responsável pela produção anual de mais de 14 milhões de toneladas de carne de frango, que é destinada a 151 países, gerando um valor bruto de produção superior a 100 bilhões de reais (MULTIMIX, 2022). A criação de aves em larga escala requer práticas de manejo avançadas. Os aviários são estruturas projetadas para a criação de aves, proporcionando um ambiente seguro e adequado para o desenvolvimento saudável dos animais.

Os aviários são projetados considerando fatores como ventilação, iluminação, temperatura e espaço disponível para garantir o bem-estar das aves. O emprego de sistemas inteligentes de gerenciamento de aves é necessário para aumentar a produção, minimizando os custos e o uso de recursos (ASTILL et al., 2020a). Os aviários inteligentes incorporam sistemas automatizados e monitoramento inteligente para otimizar o manejo das aves, garantindo condições ambientais ideais, monitoramento remoto e gestão eficiente dos recursos. As inovações têm impactado positivamente a indústria avícola, proporcionando melhorias significativas no bem-estar animal, na produtividade e no controle de custos. As granjas avícolas inteligentes podem emancipar os agricultores dos procedimentos tradicionalmente tediosos, obsoletos e demorados (ISLAM et al., 2019a).

A adoção de aviários inteligentes tem se destacado como uma abordagem promissora para o monitoramento e controle eficiente das condições de criação de aves. A integração desses sistemas com as tecnologias de Edge, Fog e Cloud Computing apresenta-se como uma solução potencialmente poderosa, permitindo a análise e gestão de dados em tempo real, bem como o processamento distribuído de informações. Ao integrar uma arquitetura de Edge Computing baseada em IoT, aplicativos e serviços fornecem aos usuários respostas mais rápidas, eficientes e seguras (AI; PENG; ZHANG, 2018). O conceito de Fog Computing surgiu como um paradigma de computação que adiciona camadas de nós de computação entre a Edge e a Cloud (PEIXOTO; GENEZ; BITTENCOURT, 2021). A Cloud Computing representa uma solução remota com recursos computacionais praticamente ilimitados (SILVA; FÉ; GONÇALVES, 2021).

Para lidar com os desafios de desempenho e escalabilidade no monitoramento inteligente de aviários, a integração entre as camadas Edge, Fog e Cloud permite uma distribuição hierárquica e eficiente das tarefas de processamento e armazenamento. Nessa arquitetura, a camada de Cloud é fundamental para o treinamento de modelos de apren-

dizado de máquina, armazenamento histórico de dados e análises de larga escala. No entanto, sua utilização no processamento em tempo real requer atenção. Por estar fisicamente distante dos dispositivos de Edge, a Cloud está sujeita a maiores tempos de resposta devido à latência de rede e à variabilidade na largura de banda disponível.

O monitoramento da produção avícola com novas tecnologias sensoriais levará à produção de grandes volumes de dados que precisam ser armazenados e prontamente acessíveis (ASTILL et al., 2020b). Embora a arquitetura distribuída em Edge, Fog e Cloud seja uma solução eficiente para gerenciar essa complexidade, ela introduz seus próprios desafios de desempenho. A camada Cloud, apesar de fundamental para análises de larga escala e armazenamento histórico, torna-se um gargalo para operações em tempo real. Sua distância física dos dispositivos na Edge causa maiores tempos de resposta devido à latência da rede. Além disso, o fluxo contínuo e volumoso de dados pode congestionar a comunicação e impactar negativamente o sistema. No contexto de um aviário, esses atrasos não afetam apenas a experiência do usuário, mas representam um risco crítico para a operação, comprometendo a tomada de decisão ágil e o monitoramento contínuo que garantem o bem-estar animal e a eficiência da produção (MAHMUD; RAMAMOHANARAO; BUYYA, 2018).

1.1 Objetivos

O objetivo geral desta monografia é propor um modelo SPN para avaliar o desempenho de uma arquitetura de um aviário inteligente integrado com Edge, Fog e Cloud Computing. O modelo ajudará a identificar pontos relevantes do sistema, potencialmente economizando custos durante a implementação do sistema real. Os objetivos específicos deste trabalho são:

- Desenvolver um modelo SPN para analisar métricas de desempenho como MRT, DP, TP e utilização de recursos em arquiteturas Edge-Fog-Cloud;
- Realizar uma análise de sensibilidade utilizando o Design of Experiments (DoE) para identificar fatores críticos que afetam o desempenho do sistema e fornecer informações para sua otimização;
- Avaliar o desempenho do sistema sob diferentes configurações de Cloud, analisando o impacto do número de cores de processamento e dos tempos de serviço sobre o MRT e demais métricas.

2 Referencial Teórico

Neste capítulo, serão descritos os conceitos essenciais para compreender esta monografia. As seguintes subseções abordarão os seguintes tópicos: aviários inteligentes, Edge, Fog e Cloud computing, SPNs, avaliação de desempenho e análise de sensibilidade com DoE.

2.1 Aviários Inteligentes

Os aviários inteligentes representam uma revolução na indústria avícola, incorporando tecnologias avançadas para melhorar o bem-estar das aves, aumentar a eficiência da produção e promover a sustentabilidade ambiental. O emprego de sistemas inteligentes de manejo avícola é necessário para aumentar a produção e, ao mesmo tempo, minimizar custos e o uso de recursos (ASTILL et al., 2020a). Os aviários inteligentes são instalações avícolas que empregam uma variedade de tecnologias inovadoras, como sensores, sistemas de monitoramento, automação e inteligência artificial, para criar um ambiente otimizado para as aves. Essas tecnologias permitem o monitoramento em tempo real das condições ambientais, como temperatura, umidade, qualidade do ar e níveis de luz, além de possibilitar a gestão automatizada de alimentação, água e ventilação.

A avicultura moderna tem se beneficiado enormemente da integração de tecnologias inteligentes nos aviários. Os benefícios da automação avícola incluem economia de mão de obra, menos custos de manutenção, economia nos custos gerais de material e melhoria na qualidade, precisão e precisão (ISLAM et al., 2019b). Os aviários inteligentes também têm um impacto significativo no bem-estar das aves. Ao monitorar constantemente o ambiente de criação e ajustá-lo conforme necessário, os aviários inteligentes podem garantir que as aves estejam sempre em condições ótimas. Isso pode levar a aves mais saudáveis e produtivas. Ademais, com o avanço contínuo da tecnologia, os aviários inteligentes têm o potencial de revolucionar a indústria avícola e criar um futuro mais sustentável para a produção de aves.

2.2 Edge, Fog e Cloud Computing

A combinação dos recursos de Edge, Fog e Cloud cria um paradigma hierárquico de IoT (FIROUZI; FARAHANI; MARINŠEK, 2022). A colaboração entre edge, fog e computação em Cloud é a melhor prática para alcançar soluções inteligentes (ALHARBI; ALDOSSARY, 2021). Cada um desses paradigmas de computação realiza uma tarefa para facilitar o funcionamento eficaz e eficiente dos dispositivos IoT (OLIVEIRA et al., 2023).

A Edge pode oferecer tempos de resposta rápidos necessários para aplicativos de IoT, mesmo com recursos limitados. Os dados podem ser filtrados e preparados para análise na Edge antes de serem enviados para nós de Cloud ou de Fog (OLIVEIRA et al., 2023). Na Edge a latência é geralmente baixa, uma vez que o processamento é realizado próximo aos dispositivos de coleta de dados.

A Fog geralmente está mais próxima da Edge do que da cloud, aliviando a carga da rede. Quando situada mais próxima dos dispositivos da Edge, a Fog fornece poder computacional limitado para o processamento dos dados coletados e apresenta baixa latência (SANTOS et al., 2018). Os avanços na Fog facilitam o fluxo de transmissão de dados e podem ser usados para análise localizada e tomada de decisões (OLIVEIRA et al., 2023). A Cloud fornece alto poder computacional e capacidade de armazenamento ilimitada, recursos escassos em dispositivos IoT (BUYYA; BROBERG; GOSCINSKI, 2010). O tempo de latência na Cloud é maior, pois envolve a transmissão dos dados pela rede. A transmissão abundante de dados certamente maximizará o tempo de resposta na Cloud (SHUKLA et al., 2021).

2.3 Redes de Petri Estocásticas

As Redes de Petri (PN) são ferramentas de modelagem gráfica e matemática usadas para representar diferentes tipos de sistemas, caracterizados por simultaneidade, assincronia, distribuição, paralelismo, não determinismo, e/ou processos estocásticos (CHEN; HA, 2018). As PNs oferecem um conjunto de formalismos para abstrair sistemas complexos. Além disso, existem várias ferramentas de software que facilitam sua modelagem, análise e verificação (GIRAULT; VALK, 2013). SPNs são casos especiais de PNs. Modelos SPN foram propostos com o objetivo de desenvolver uma ferramenta que permitisse a integração de descrição formal, prova de correção e avaliação de desempenho (SILVA et al., 2018). A ausência de paralelismo em Markov e as limitações dos modelos de fila na representação de comportamentos complexos justificam a preferência pelo uso de modelos SPN.

As SPNs podem ser identificadas como um tipo de grafo direcionado dividido em duas partes, preenchido por três tipos de objetos. Esses objetos são lugares, transições e arcos direcionados que conectam os lugares para as transições e transições aos lugares (RODRIGUES et al., 2020). A transição temporizada segue um comportamento estocástico, seguindo uma função de distribuição de probabilidade (MURATA, 1989). A transição imediata dispara quando é ativada, sem esperar por nenhum período específico. O círculo branco simboliza os lugares. Arcos são usados para conectar lugares a transições. Arcos inibidores bloqueiam ou permitem a passagem de tokens de um lugar para outro. Além disso, o token é atribuído a um lugar específico (BRITO et al., 2021). A Figura 1 apresenta os componentes de um modelo SPN.




Figura 1 – Componentes SPNs.

2.4 Avaliação de Desempenho

A avaliação de desempenho em sistemas é fundamental para assegurar operações eficientes. Esse processo analisa a eficácia de diversos componentes, identificando gargalos e oportunidades de melhoria. Diferentes metodologias são empregadas para esse propósito, como avaliação baseada em modelos, avaliação multicritério e análise de interação com as partes interessadas (YATSYSHYN et al., 2023). A avaliação de desempenho em sistemas é uma prática essencial tanto no desenvolvimento quanto na manutenção de sistemas de software. Ela consiste em analisar e medir o comportamento de um sistema em relação a critérios pré-definidos, a fim de identificar áreas de melhoria, diagnosticar problemas e garantir que o sistema atenda aos requisitos de desempenho estabelecidos. Ao compreender melhor o desempenho do sistema, os gestores podem tomar decisões mais informadas para otimizar suas operações.

A avaliação de desempenho em sistemas é crucial para uma compreensão clara das tarefas, rastreamento do progresso em tempo real e monitoramento efetivo entre avaliadores e indivíduos avaliados, aumentando a eficiência e a transparência geral do sistema (JUAN; YANBIN; NENGQUAN, 2017). Além disso, uma das principais metodologias utilizadas é a análise de desempenho. Esta análise envolve a coleta de métricas relevantes, como tempo de resposta, throughput, e utilização de recursos. Esta análise permite identificar possíveis problemas de desempenho, como gargalos e ineficiências, e fornece visões valiosas para a otimização do sistema.

2.5 Análise de Sensibilidade com DoE

O DoE corresponde a um conjunto de técnicas estatísticas que aprofundam a compreensão do produto ou processo em estudo (KLEIJNEN, 1995). O DoE é uma técnica poderosa usada para explorar novos processos e obter visões mais profundas sobre processos existentes, seguidos pela otimização desses processos para alcançar um desempenho de classe mundial (ANTONY, 2014). Também pode ser definido como uma série de testes nos quais o pesquisador manipula o conjunto de variáveis ou fatores de entrada a serem observados e identifica as razões para as mudanças na resposta de saída. Além disso, um DoE adequado permite obter informações valiosas com um número mínimo de experimentos,

maximizando a eficiência e reduzindo os custos.

Os designers de sistemas frequentemente adotam análises de sensibilidade para avaliar quão "sensível" uma métrica é a mudanças no modelo (SANTOS et al., 2021). A análise de sensibilidade mede o impacto de dados de entrada específicos nos dados de saída para identificar pontos fracos em sistemas computacionais. Posteriormente, técnicas são empregadas para aprimorar esses sistemas em vários cenários (CAMPOLONGO; TARANTOLA; SALTELLI, 1999). O gráfico de Pareto nos permite identificar qual interação de fatores tem um efeito mais significativo no processo de otimização ou no design do estudo, indicando onde a atenção deve ser focada. Compreender a magnitude das interações entre os fatores permite a seleção da melhor combinação de medidas, identificando padrões de efeitos cumulativos ou degradantes entre os fatores. A interação entre os fatores A e B pode ser calculada usando a Equação (2.1).

$$I_{A,B} = \frac{1}{2}(E_{A,B(+1)} - E_{A,B(-1)}) \quad (2.1)$$

O $E_{A,B(+1)}$ representa o efeito do fator A no nível alto do fator B, e $E_{A,B(-1)}$ representa o efeito do fator A no nível baixo do fator B. Se as linhas no gráfico de interação são paralelas, não há interação entre os parâmetros do processo. Os diferentes níveis do fator B não influenciam a variação na resposta média do fator A. Por outro lado, se as linhas não são paralelas, há uma interação entre os fatores. Quanto maior a divergência do paralelismo, mais significativo é o efeito de interação entre esses fatores.

3 Trabalhos Relacionados

Esta capítulo apresenta trabalhos relacionados com abordagens ou contextos semelhantes a este estudo. Os trabalhos selecionados abordam o contexto da avaliação de desempenho na agricultura inteligente. Os artigos consideraram os métodos de avaliação, as métricas analisadas e se utilizaram Computação de Edge, Fog ou Cloud individualmente, ou combinadas em uma única arquitetura. Os trabalhos relacionados foram classificados em dois grupos com base no método de avaliação. A escolha do método de avaliação de desempenho é crucial porque afeta a objetividade, custos e viabilidade da avaliação. A Tabela 1 exibe os trabalhos selecionados na literatura junto com seus respectivos critérios de seleção.

3.1 Trabalhos Baseados em Mensuração

A primeira classificação aborda os trabalhos que utilizaram a mensuração como método de avaliação. O trabalho de (PARK et al., 2022) propõe uma avaliação de desempenho de uma plataforma de visualização de Agricultura Inteligente baseada em LoRaWAN. O estudo de (POOJA et al., 2017) apresenta uma solução de agricultura inteligente baseada no protocolo MQTT para coleta contínua de dados ambientais no campo e o desenvolvimento e implementação de tecnologia inteligente para o setor agrícola. O trabalho de (KUMAR et al., 2022) propõe um sistema inteligente de monitoramento e gestão agrícola usando o controlador de Automação de Dados Auto-Sincronizados (SSDA) para melhorar o setor agrícola. O estudo de (MULYA et al., 2024) propõe um sistema de monitoramento de fazendas de aves baseado em IoT que permite a coleta e análise de dados em tempo real, visando prevenir surtos de doenças, otimizar o consumo de ração e criar condições de vida ideais para as aves.

O trabalho de (OJO; ADAMI; GIORDANO, 2020) apresenta uma avaliação de desempenho de uma solução IoT para agricultura de precisão para repelir ungulados e prevenir danos a áreas de cultivo. O trabalho de (ABBA et al., 2019) visa desenvolver uma interface de sensor autônoma de baixo custo para automação do monitoramento e controle de sistemas de irrigação em locais remotos. O estudo de (MALIK et al., 2020) introduz uma estrutura projetada para fornecer um ecossistema agrícola completo e benchmarks em atraso de transmissão, taxa de entrega de pacotes e consumo de energia. O trabalho de (SABO; UMARU; YUSUF, 2025) apresenta um controlador inteligente de aviários baseado em IoT para monitorar e regular parâmetros ambientais essenciais, como temperatura, umidade e iluminação.

3.2 Trabalhos Baseados em Simulação

A segunda classificação lida com trabalhos que utilizaram a simulação como método de avaliação. O estudo de (HUO et al., 2022) apresenta uma pilha de simulação onde os resultados da simulação de uma ampla variedade de cenários reais são usados para aprimorar o desempenho subsequente do sistema agrícola proposto em cenários de grande escala. O trabalho de (MILES et al., 2020) fornece um estudo detalhado do desempenho da rede de comunicação LoRaWAN no contexto de uma aplicação IoT para uma fazenda.

O estudo de (GUILLÉN et al., 2021) explora a Edge como uma solução para preencher a lacuna entre IA e IoT em ambientes rurais, considerando o desempenho e o consumo de energia. O trabalho de (AHMAD et al., 2021) propõe um sistema para automatizar o monitoramento de plantas e jardinagem inteligente, reduzindo o esforço manual e melhorando a eficiência da produção agrícola. O trabalho de (AZAD; PADHY; DASH, 2023) introduz uma função de roteador múltiplo como links intermediários entre sensores e receptores em uma rede IoT, garantindo comunicação confiável e monitoramento da fazenda. O estudo de (YASCARIBAY et al., 2022) apresenta um método que pode ser usado para avaliação de desempenho de sistemas de comunicação utilizados em IoT para a agricultura.

3.3 Contribuições Desta Monografia

Esta monografia propõe um modelo baseado em SPN para a avaliação de desempenho de um aviário inteligente. A modelagem SPN destaca-se por ser uma abordagem de baixo custo, com rigor formal e alta capacidade de generalização, dispensando a necessidade de infraestrutura física para a avaliação, em contraste com as abordagens mais comuns na literatura, como mensuração empírica e simulação. A modelagem abstrata permite prever o comportamento do sistema em diferentes condições operacionais, inclusive em cenários ainda não observados. O modelo desenvolvido contempla métricas essenciais como MRT, TP, DP e utilização de recursos, aspectos raramente integrados de forma conjunta nos trabalhos existentes.

Adicionalmente, foi realizada uma análise de sensibilidade baseada em DoE, permitindo observar como variações nos parâmetros impactam o desempenho, especialmente em relação ao MRT. A consideração de uma arquitetura Edge-Fog-Cloud representa um diferencial significativo frente aos estudos que tratam apenas camadas isoladas. Por fim, o modelo desenvolvido permite que projetistas ajustem parâmetros de entrada para adaptá-lo a diferentes contextos de operação, mantendo flexibilidade e reduzindo custos associados à infraestrutura física.

Tabela 1 – Trabalhos relacionados.

Trabalho	Método de Avaliação	Métricas	Tipo de Arquitetura
(PARK et al., 2022)	Mensuração	Utilização e tempo de resposta	Cloud
(HUO et al., 2022)	Simulação	Taxa de entrega de pacotes	Edge
(MILES et al., 2020)	Simulação	Taxa de entrega de pacotes, consumo de energia e taxa de transmissão de dados	Cloud
(POOJA et al., 2017)	Mensuração	Taxa de baud e consumo de energia	Edge-Cloud
(GUILLÉN et al., 2021)	Simulação	Tempo de execução e consumo de energia	Edge
(KUMAR et al., 2022)	Mensuração	Consumo de energia e taxa de transferência	Edge
(AHMAD et al., 2021)	Simulação	Temperatura, umidade e quantidade de água	Edge-Cloud
(AZAD; PADHY; DASH, 2023)	Simulação	Taxa de erro de bit, taxa de erro de pacote, taxa de perda de pacote e indicador de força do sinal recebido	Edge
(OJO; ADAMI; GIORDANO, 2020)	Mensuração	Confiabilidade da rede e taxa de entrega de pacotes	Cloud
(ABBA et al., 2019)	Mensuração	Temperatura, umidade e pressão	Cloud
(YASCARIBAY et al., 2022)	Simulação	Taxa de entrega de pacotes, colisões de pacotes e consumo de energia	Cloud
(MALIK et al., 2020)	Mensuração	Utilização, consumo de energia e taxa de entrega de pacotes	Cloud
(MULYA et al., 2024)	Mensuração	Temperatura, umidade, temperatura da CPU, taxas de dados de uplink	Edge-Cloud
(SABO; UMARU; YUSUF, 2025)	Mensuração	Temperatura, umidade, luz, temperatura da CPU, taxas de dados de uplink, tensão do sistema elétrico	Edge-Cloud
Este Trabalho	Modelagem	MRT, DP, TP, utilização	Edge-Fog-Cloud

4 Arquitetura

Este capítulo apresenta a arquitetura modelada nesta monografia, com foco em um aviário inteligente voltado à coleta de dados por meio de dispositivos IoT, cujo processamento ocorre de forma distribuída nas camadas Edge, Fog e Cloud. São discutidos os principais componentes do aviário e sua estrutura em múltiplas camadas, de modo a esclarecer as responsabilidades e interações entre elas. A arquitetura proposta para fábricas de produção avícola inteligente, ilustrada na Figura 2, foi baseada em estudos que abordam operações em granjas, monitoramento ambiental, manutenção preventiva e os paradigmas de computação em Cloud e IoT (OLIVEIRA et al., 2023; ASTILL et al., 2020b; CHOUKIDAR; DAWANDE, 2017; ISLAM et al., 2019c; SO-IN; POOLSANGUAN; RUJIRAKUL, 2014). Embora este estudo não envolva a implementação física do sistema, a arquitetura serve como base conceitual para geração de dados e modelagem estocástica.




Figura 2 – Arquitetura do Sistema do Aviário Inteligente.

No aviário, diversos sensores IoT são utilizados para monitorar o ambiente e garantir o bem-estar das aves. Sensores de luminosidade controlam os níveis de luz artificial

para otimizar a saúde e a produção de ovos. Sensores de temperatura gerenciam o clima, acionando sistemas de ventilação ou aquecimento automaticamente. Sensores de nível de água monitoram a disponibilidade hídrica, garantindo o fornecimento contínuo e acionando alertas para reposição quando necessário. Sensores de gás avaliam a qualidade do ar, identificando concentrações de gases nocivos ou essenciais, como amônia ou dióxido de carbono. Esses sensores, em conjunto, otimizam as condições do aviário, promovendo o bem-estar das aves e aumentando a produção de ovos.

Os dados capturados por esses sensores são processados em três camadas computacionais. A camada Edge, instalada próxima ao aviário, realiza o processamento inicial e o controle em tempo real por meio de gateways conectados aos sensores. A camada Fog, situada em um nível intermediário consolida os dados recebidos, realiza análises locais mais complexas e armazena informações relevantes temporariamente. Por fim, os dados são transmitidos à camada Cloud que fornece poder computacional adicional para análises históricas, treinamento de modelos de predição e geração de relatórios. Apesar da proximidade física com o sistema, o envio de dados à Cloud ainda implica latência adicional em relação às camadas Edge e Fog, justificando sua utilização apenas para tarefas menos sensíveis ao tempo.

5 Modelo SPN

Neste capítulo, é apresentada uma análise detalhada do modelo de arquitetura, com foco na modelagem por meio de SPN. As SPNs, uma forma especializada de PNs, incorporam elementos estocásticos para simular sistemas do mundo real sem a necessidade de implementação física. A arquitetura básica e o fluxo de modelagem, ilustrados na Figura 3, permitem representar sistemas que ainda não possuem uma estrutura física existente.




Figura 3 – Fluxograma da arquitetura.

Na modelagem do sistema inteligente de avicultura, o primeiro passo consiste no estabelecimento da entrada de dados, representada como admissões na modelagem SPN, o que corresponde aos dados dos sensores dentro da arquitetura. Os dados dos sensores são transmitidos para a camada Edge para pré-processamento inicial. Em seguida, os dados processados são encaminhados para a camada Fog, onde ocorre um processamento intermediário em múltiplos nós. A camada Fog atua como uma ponte entre a Edge e a Cloud, garantindo um fluxo de dados contínuo. Após o processamento na névoa, os dados são enviados para a Cloud para processamento adicional e armazenamento em servidores, que podem ser ajustados conforme as demandas do sistema.

Componentes entre as camadas, representando switches e roteadores, estão incluídos no modelo. Para simplificar o modelo, cada nó ou servidor é representado por dois triângulos horizontais numerados de 1 a 3. Essa abordagem facilita a replicação, uma vez que todos os componentes estão rotulados. Assume-se que um nó físico atua como uma junção entre o hardware e o sistema operacional e, na Cloud, representa uma instância de máquina virtual. Além disso, presume-se que switches e roteadores estão sempre conectados, que os sensores transmitem dados em tempo real, e que o sistema está sempre disponível para processar os dados, desconsiderando interferências na modelagem. Os parâmetros do modelo podem ser ajustados conforme os requisitos dos administradores e projetistas do

sistema. Os dados utilizados para embasar o modelo são provenientes de observações na literatura, garantindo uma modelagem prática e relevante.

5.1 Modelagem da Arquitetura

A Figura 4 apresenta o modelo SPN específico para a arquitetura de avicultura inteligente com a combinação de Edge, Fog e Cloud, conforme descrito anteriormente. O modelo está organizado em quatro partes: *Admission*, *Edge*, *Fog* e *Cloud*. Devido à natureza extensa do modelo, para melhor visualização, ele será apresentado em partes do modelo original a fim de facilitar o entendimento do seu funcionamento. As Figuras 5 e 6 mostram, respectivamente, a operação das camadas *Edge*, *Fog* e *Cloud* no modelo SPN proposto




Figura 4 – Modelo SPN da Arquitetura Proposta.

O bloco *Admission* é o ponto de entrada para novas requisições. Em seguida, o bloco *Edge* processa essas requisições como a primeira camada. As requisições então progridem para o bloco *Fog*, que atua como intermediário no processamento das requisições oriundas do *Edge* e as transfere para a próxima etapa. Por fim, o bloco *Cloud* realiza o processamento final das requisições. A Tabela 2 fornece descrições detalhadas dos componentes do modelo. Componentes semelhantes entre diferentes blocos foram agrupados para melhorar a clareza e compreensão, e foram fornecidas descrições para elementos representativos de cada bloco.

A Figura 5 ilustra a fase de *Admission* e da *Edge* do modelo. O bloco *Admission* é composto por dois lugares, *Par* e *Pqar*, que representam os intervalos entre a chegada das requisições e sua aceitação na fila. Os tokens em *Par* e *Pqar* denotam requisições de entrada de dados prontas para processamento. Os tempos de chegada das tarefas são atribuídos à transição *Tar*. Assume-se que as chegadas das tarefas seguem uma distribuição exponencial, embora isso possa ser ajustado para outras distribuições. A transição imediata *T1* representa a entrada instantânea de mensagens no sistema, sem atrasos de execução.

Como *Edge*, *Fog* e *Cloud* compartilham funcionalidades similares, a explicação a seguir foca no *Edge*. A parte da *Edge* consiste em dois lugares de entrada, *Pqcre* e *Pqre*. A




Figura 6 – As partes que representam a camada Fog e a camada Cloud.

Tabela 2 – Componentes do modelo SPN

Tipo	Componentes	Descrição
Lugares	Par	Novas requisições
	Parq	Disponibilidade da fila
	Pqcre, Pqcrf, Pqcrc	Capacidade da fila dos roteadores do Edge, Fog e Cloud
	Pqre, Pqrf, Pqrc	Fila nos roteadores do Edge, Fog e Cloud
	Pqce1, Pqcf1, Pqcc1	Capacidade da fila no Edge, Fog e Cloud
	Pqe1, Pqf1, Pqc1	Fila no Edge, Fog e Cloud
	Pqpe1, Pqpfl, Pqpc1	Capacidade de processamento paralelo do Edge, Fog e Cloud
	Ppe1, Ppfl, Ppc1	Fila de processamento no Edge, Fog e Cloud
Transições	T2, T3, T4	Intervalo de tempo entre requisições no Edge, Fog e Cloud
	Tar	Tempo entre chegadas de requisições
	Tpe1, Tpf1, Tpc1	Tempo para processar uma requisição no Edge, Fog e Cloud
Tokens	CapRE, CapRF, CapRC	Capacidade máxima da fila dos roteadores do Edge, Fog e Cloud
	CapE, CapF, CapC	Capacidade máxima da fila do Edge, Fog e Cloud
	NuE, NuF, NuC	Número de recursos para processamento no Edge, Fog e Cloud

5.2 Métricas

Esta seção apresenta as métricas de interesse obtidas a partir do modelo. Foram avaliadas quatro métricas relevantes: (1) MRT, (2) DP, (3) utilização da CCloud e (4) TP. A seguir, descrevemos como cada uma dessas métricas é obtida a partir do modelo SPN.

A Equação 5.1 define o MRT do sistema. O MRT pode ser obtido a partir da Lei de Little (LITTLE, 1961), que relaciona o número médio de requisições em andamento em um sistema, a taxa de chegada (AR) e o MRT. O AR é o inverso do tempo entre chegadas

(Atraso de Chegada - AD) (RODRIGUES et al., 2021). Para a transição de tempo de chegada no modelo, temos $AR = \frac{1}{AD}$.

$$\mathbf{MRT} = \frac{\text{RequisiçõesEmAndamento} \times AD}{1 - DP} \quad (5.1)$$

A *RequisiçõesEmAndamento* é determinado por $Esp(Place)$, que representa a soma das expectativas estatísticas da existência de tokens em lugares relacionados às tarefas. O cálculo de *RequisiçõesEmAndamento* é definido como:

$$\begin{aligned} \mathbf{RequisiçõesEmAndamento} = & Esp(Pgre) + Esp(Pqe1) + Esp(Ppe1) \\ & + Esp(Pqe2) + Esp(Ppe2) + Esp(Pqe3) + Esp(Ppe3) \\ & + Esp(Pqrf) + Esp(Pqf1) + Esp(Ppf1) + Esp(Pqf2) \\ & + Esp(Ppf2) + Esp(Pqf3) + Esp(Ppf3) + Esp(Pqrc) \\ & + Esp(Pqc1) + Esp(Ppc1) + Esp(Pqc2) + Esp(Ppc2) \\ & + Esp(Pqc3) + Esp(Ppc3) + Esp(Pi1) + Esp(Pi2) + Esp(Pi3) \end{aligned}$$

A Equação 5.2 define o DP. A probabilidade de descarte é calculada pela probabilidade de existência de tokens em um local específico. Para calcular o DP no modelo proposto, avaliamos a probabilidade de descarte de requisições no roteador da Edge. As requisições que não são transferidas do roteador para a Edge indicam um problema, já que é nesse ponto que os dados entram para serem processados no sistema.

$$\mathbf{DP} = P(Pqcre = 0) \times 100 \quad (5.2)$$

A Equação 5.3 define a utilização de recursos da Cloud. A utilização refere-se à proporção de tempo em que os recursos disponíveis estão sendo efetivamente utilizados. A utilização dos recursos da Cloud é calculada pela expectativa de existência de tokens na fila de processamento, dividida pela capacidade de processamento da Cloud.

$$\mathbf{Utilização\ de\ Recursos} = \frac{Esp(Ppc1)}{NuC} \times 100 \quad (5.3)$$

A Equação 5.4 define o TP. O TP é uma medida quantitativa que indica o número de requisições processadas com sucesso pelo sistema em um determinado período. O TP é calculado pela expectativa de existência de tokens na fila que representa a capacidade da Cloud, dividida pelo tempo de serviço dessa camada.

$$\mathbf{TP} = \frac{Esp(Pqc1)}{\text{Tempo de Serviço}} \quad (5.4)$$

6 Design of Experiments

Este capítulo apresenta os resultados das análises realizadas sobre os fatores que influenciam o desempenho do sistema, utilizando o modelo SPN. O foco está em compreender como cada fator afeta o desempenho e identificar possíveis interações. A principal métrica utilizada para avaliar o desempenho é o MRT.

6.1 Análise de Sensibilidade Utilizando DoE

O DoE é uma técnica estatística para planejar, conduzir e analisar experimentos de forma sistemática (ILZARBE et al., 2008). Ele auxilia os pesquisadores a entender e otimizar processos, identificando fatores influentes e suas interações. A análise de sensibilidade complementa o DoE ao quantificar o impacto das variações de entrada sobre as métricas de saída, ajudando na identificação de parâmetros críticos. Esses métodos são fundamentais para otimizar o desempenho de sistemas de forma eficiente e econômica em ambientes complexos.

Este experimento baseou-se na arquitetura estudada, explorando diferentes camadas arquiteturais por meio da análise de sensibilidade. Apenas os fatores que apresentaram interações significativas são apresentados. Essas interações foram avaliadas com base na métrica MRT, pois ela impacta diretamente a experiência do usuário final. As demais métricas foram consideradas secundárias.

Os fatores selecionados para este estudo foram: (i) NuE, (ii) NuF, (iii) NuC, (iv) CapC e (v) ST_C. Cada fator foi analisado em dois níveis: configuração baixa e alta. A Tabela 3 lista todos os fatores e os níveis analisados. Além disso, a Tabela 4 apresenta todas as combinações possíveis dos fatores e seus respectivos níveis.

Tabela 3 – Fatores e níveis da simulação.

Nome do fator	Configuração baixa	Configuração alta
NuE	4.0	8.0
NuF	4.0	6.0
NuC	2.0	4.0
CapC	25.0	50.0
ST_C	100.0	200.0

6.2 Resultados do DoE

O gráfico de efeito dos fatores, mostrado na Figura 7, exibe o impacto dos fatores sobre a métrica analisada, com as barras organizadas em ordem decrescente. A altura de cada

Tabela 4 – Combinações de níveis e fatores.

NuE	NuF	NuC	CapC	ST_C	MRT (ms)
4.00	4.00	2.00	25.00	100.00	6737.27
4.00	4.00	2.00	25.00	200.00	19517.87
4.00	4.00	2.00	50.00	100.00	6336.25
4.00	4.00	2.00	50.00	200.00	19154.52
4.00	4.00	4.00	25.00	100.00	1853.28
4.00	4.00	4.00	25.00	200.00	6151.09
4.00	4.00	4.00	50.00	100.00	1951.49
4.00	4.00	4.00	50.00	200.00	6082.46
4.00	6.00	2.00	25.00	100.00	7196.43
4.00	6.00	2.00	25.00	200.00	20256.76
4.00	6.00	2.00	50.00	100.00	6792.91
4.00	6.00	2.00	50.00	200.00	18137.13
4.00	6.00	4.00	25.00	100.00	1704.26
4.00	6.00	4.00	25.00	200.00	6644.98
4.00	6.00	4.00	50.00	100.00	1493.26
4.00	6.00	4.00	50.00	200.00	6736.28
8.00	4.00	2.00	25.00	100.00	6087.01
8.00	4.00	2.00	25.00	200.00	20345.98
8.00	4.00	2.00	50.00	100.00	6085.83
8.00	4.00	2.00	50.00	200.00	17467.50
8.00	4.00	4.00	25.00	100.00	1877.53
8.00	4.00	4.00	25.00	200.00	6426.50
8.00	4.00	4.00	50.00	100.00	1731.92
8.00	4.00	4.00	50.00	200.00	6362.63
8.00	6.00	2.00	25.00	100.00	6515.99
8.00	6.00	2.00	25.00	200.00	20466.68
8.00	6.00	2.00	50.00	100.00	6189.60
8.00	6.00	2.00	50.00	200.00	18112.29
8.00	6.00	4.00	25.00	100.00	1793.43
8.00	6.00	4.00	25.00	200.00	6471.97
8.00	6.00	4.00	50.00	100.00	1696.11
8.00	6.00	4.00	50.00	200.00	6308.29

barra indica a influência do fator correspondente, destacando aqueles com os efeitos mais significativos na métrica MRT. Essa ferramenta visual permite identificar quais fatores causam variações substanciais nos resultados dos testes quando seus níveis são ajustados.

O tempo de serviço e o número de cores de processamento na Cloud são identificados como os fatores mais influentes nesta análise, sendo essenciais para melhorar a eficiência do processamento de dados. Embora o gráfico de efeito dos fatores forneça uma visão sobre o impacto absoluto desses fatores, ele não indica se eles aumentam ou diminuem o tempo de resposta. A Figura 8 ilustra as interações entre esses fatores-chave e seus efeitos sobre a métrica MRT.

Na Figura 8(a), é apresentada a interação entre os fatores CapC e ST_C. Definir a




Figura 7 – Impacto da combinação de fatores na métrica MRT.

capacidade da fila na Cloud para 25 otimiza o tempo de serviço em 100 ms, resultando em um MRT ligeiramente acima de 8400 ms. Por outro lado, aumentar a capacidade da fila para 50 permite um tempo de serviço de 200 ms, levando a um MRT inferior a 8200 ms. Isso sugere que uma maior capacidade de fila pode acomodar tempos de serviço mais longos, mantendo um MRT mais baixo, indicando uma gestão eficaz dos tempos de espera.




Figura 8 – Análise das interações entre fatores da Cloud e sua influência sobre a métrica MRT.

A Figura 8(b) demonstra a interação entre os fatores NuC e CapC. Com dois cores de processamento na Cloud, o MRT ideal é alcançado com uma fila de tamanho 50, resultando em um MRT de aproximadamente 8400 ms. Ao aumentar o número de cores para quatro, é possível reduzir a fila para 25, alcançando um MRT inferior a 8200 ms. Isso indica que mais cores de processamento permitem uma fila menor sem afetar significativamente o MRT.

A Figura 8(c) mostra a interação entre os fatores NuC e ST_C. Com dois cores de processamento, um tempo de serviço de 100 ms resulta em um MRT inferior a 7000 ms.

Ao aumentar o número de cores para quatro, observa-se que um tempo de serviço de 200 ms também mantém o MRT abaixo de 7000 ms, indicando que um maior número de cores permite tempos de processamento mais longos mantendo a eficiência do MRT.

Esses resultados destacam a importância de equilibrar os recursos e configurações do sistema para otimizar o desempenho. Por meio do DoE e da análise de sensibilidade, é possível identificar os fatores críticos e suas interações, permitindo melhorias direcionadas no projeto do sistema.

7 Casos de Estudo

Este capítulo apresenta duas análises numéricas de desempenho do modelo SPN do modelo proposto nesta monografia. As análises numéricas do modelo consideram que o MRT é um fator bastante relevante, pois é importante monitorar as aves em tempo real, sendo essencial que o sistema retorne uma resposta o mais rapidamente possível. O primeiro cenário avalia a variação no número de cores disponíveis para o processamento de dados na Cloud. O segundo cenário, que representa um desafio significativo, avalia a variação no tempo de serviço da camada da Cloud. Esses cenários foram escolhidos porque tarefas de alto nível são executadas na camada Cloud, exigindo mais tempo e maior capacidade de processamento. Além disso, na análise do DoE, a Cloud destacou-se por conter dois dos fatores mais influentes no modelo. Como essa camada é a mais distante e possui maior latência em relação às demais, qualquer atraso no processamento impacta significativamente o desempenho do sistema.

Toda a modelagem e os resultados foram realizados utilizando a ferramenta Mercury (MACIEL et al., 2017). Essa ferramenta foi escolhida por sua robustez na avaliação de desempenho de sistemas modelados com SPN, sendo capaz de calcular as métricas abordadas neste trabalho. Durante as simulações na ferramenta, foram adotados um nível de confiança de 95% e um erro relativo máximo de 10%, garantindo alta confiabilidade nos resultados. A simulação possibilitou a análise da variação da AR das requisições, permitindo a simulação de cenários de alta carga de trabalho. Além disso, a ferramenta Mercury foi configurada para realizar análises estruturais e validar os modelos por meio do *token game* (PINHEIRO et al., 2021), garantindo que as regras lógicas e os fluxos de processamento fossem corretamente implementados. Essas análises permitiram explorar o impacto de diferentes configurações na arquitetura, otimizando a distribuição de tarefas entre as camadas para melhorar o desempenho do sistema.

Na Tabela 5, são detalhados os valores base atribuídos às transições temporizadas e marcações no modelo SPN para a análise dos cenários. As transições temporizadas que representam a latência foram configuradas da seguinte forma: 0,1 ms para a camada Edge, 0,5 ms para a camada Fog e 1 ms para a camada Cloud, refletindo o aumento da latência conforme a distância entre as camadas. Os tempos de processamento seguem esse mesmo padrão, sendo a camada Edge a mais rápida e a camada Cloud a mais lenta. A capacidade das filas e os recursos dos roteadores foram configurados de forma a minimizar seu impacto, alocando mais recursos para as camadas Edge e Fog, a fim de evitar gargalos, uma vez que os requisitos de recursos da Cloud variam nas análises. Todas as transições temporizadas são medidas em milissegundos.

Tabela 5 – Valores atribuídos às transições e marcações do modelo SPN.

Tipo	Componentes	Valores
Transições Temporizadas	Tar (AD)	5
	T2	0,1
	Tpe1, Tpe2 e Tpe3	10
	T3	0,5
	Tpf1, Tpf2 e pf3	40
	T4	1
	Tpc1, Tpc2 e Tpc3	100
Marcações	CapRE, CapRF e CapRC	50
	CapE, CapF e CapC	50
	NuE	8
	NuF	6
	NuC	4

7.1 Cenário 1 - Variação no Número de Cores de Processamento na Cloud

No primeiro cenário, analisa-se o impacto da variação do número de cores de processamento na Cloud. O número de cores representa os servidores disponíveis para execução das tarefas, sendo que mais cores permitem o processamento simultâneo de mais tarefas. Os valores utilizados nesta avaliação estão listados na Tabela 6, e os gráficos resultantes são apresentados na Figura 9.

Tabela 6 – Valores utilizados no Cenário 1.

Tipos	Componentes	Valores
Transições Temporizadas	T4	1
	Tpc1, Tpc2 e Tpc3	100
Lugares Marcados	Pqpc1, Pqpc2, Pqpc3	[2 - 4 - 8]

A Figura 9(a) ilustra os resultados para o MRT, demonstrando claramente a correlação direta entre o número de cores e o MRT. À medida que o número de cores na Cloud aumenta, o MRT diminui. Com dois cores, observa-se um pico significativo no MRT quando a AR atinge 0,30 msg/ms, indicando que há mais requisições do que capacidade de processamento. Com quatro cores, não há pico acentuado; quando a AR está entre 0,23 e 0,30 msg/ms, o MRT atinge 5000 ms. Com oito cores, o MRT apresenta desempenho superior, mantendo-se estável até uma AR de 0,23 msg/ms, sem ultrapassar 1000 ms.

A Figura 9(b) apresenta a probabilidade de descarte, que aumenta com a redução do número de cores. No experimento com dois cores, a probabilidade de descarte aumenta gradualmente, ultrapassando 70% quando a AR excede 0,30 msg/ms. No caso de quatro cores, o comportamento é semelhante, com aumento gradual a partir de uma AR de 0,13 msg/ms, mantendo-se entre 50% e 55%. Com oito cores, a probabilidade de descarte é quase nula, apresentando apenas uma pequena variação quando a AR ultrapassa




Figura 9 – Resultados da variação no número de cores de processamento na Cloud.

0,27 msg/ms. Nesse cenário, observa-se que quanto menor o número de cores, maior é a probabilidade de descarte.

A Figura 9(c) mostra a utilização da camada de Cloud. Com dois cores, a partir de uma AR de 0,07 msg/ms, observa-se um aumento acentuado na utilização dessa camada. Após esse salto, a utilização permanece uniforme, alcançando quase 100%. Com quatro e oito cores, observa-se comportamento semelhante. Com quatro cores, o aumento ocorre após a AR ultrapassar 0,13 msg/ms, atingindo quase 100%, enquanto com oito cores, ocorre após a AR chegar a 0,27 msg/ms, atingindo pouco mais de 90% de utilização.

A Figura 9(d) apresenta a vazão do sistema. Com dois cores, a vazão é baixa, atingindo 0,06 ms quando a AR é 0,07 msg/ms e estabilizando-se. Com quatro cores, o resultado é semelhante, porém superior, alcançando 0,12 ms quando a AR chega a 0,13 msg/ms. Com oito cores, a vazão apresenta um desempenho superior, atingindo quase 0,24 ms. Esse resultado era esperado, pois a vazão tende a ser maior com mais cores de processamento.

7.2 Cenário 2 - Variação no Tempo de Processamento na Cloud

Neste cenário, foram realizadas análises comparativas das mesmas métricas do cenário anterior, mas com variações no tempo de processamento da Cloud. O tempo de processamento pode variar devido a diferentes fatores, como demanda por recursos, tamanho da carga de trabalho, complexidade e possibilidade de sobrecarga na camada, o que pode impactar negativamente o tempo de resposta. A Tabela 7 apresenta os valores utilizados no cenário 2 para analisar o desempenho em relação ao tempo de processamento. A Figura 10 mostra os resultados obtidos no sistema devido a essa variação.

Tabela 7 – Valores utilizados no Cenário 2.


Tipos	Componentes	Valores
Transições Temporizadas	T4	1
	Tpc1, Tpc2 e Tpc3	[100 - 200 - 400]
Lugares Marcados	Pqpc1, Pqpc2, Pqpc3	4

A Figura 10(a) apresenta os resultados do MRT neste cenário. É evidente que, à medida que o tempo de serviço aumenta, o MRT também aumenta. Essa tendência ocorre porque o sistema precisa de mais tempo para processar as requisições. Com um tempo de serviço de 100 ms, o MRT aumentou para 5000 ms quando a AR foi de 0,10 msg/ms. Com o tempo de serviço de 200 ms, observou-se um aumento no MRT ao atingir a mesma AR, resultando em um MRT de 15000 ms. Para o tempo de serviço de 400 ms, houve aumento no MRT quando a AR ultrapassou 0,17 msg/ms, atingindo um pico de pouco mais de 45000 ms.


A Figura 10(b) mostra a probabilidade de descarte com variações no tempo de serviço. Ao analisar o processamento com duração de 100 ms, observou-se que a taxa de descarte aumentou em quase 60% quando a AR ultrapassou 0,13 msg/ms. Ao aumentar a duração para 200 ms, verificou-se que a taxa de descarte chegou a quase 80% assim que a AR superou 0,27 msg/ms. No pior cenário, com duração de 400 ms, observou-se uma alta probabilidade de descarte, atingindo até 85%.

A Figura 10(c) exibe os resultados de utilização da camada de Cloud. É evidente que, neste cenário, à medida que a AR aumenta, todas as variações de tempo de serviço resultam em 100% de utilização da Cloud. Com tempo de serviço de 100 ms, a utilização atinge 100% quando a AR chega a quase 0,13 msg/ms. Com 200 ms, isso ocorre quando a AR está em 0,07 msg/ms. Com 400 ms, a utilização chega a 100% com AR de apenas 0,03 msg/ms.


A Figura 10(d) ilustra os resultados da vazão do sistema. Com tempo de serviço de 100 ms, a vazão do sistema apresenta desempenho superior, atingindo quase 0,12 ms. Esse resultado era esperado, pois a vazão tende a ser maior com tempos de serviço menores. Com 200 ms, a vazão atinge 0,06 ms quando a AR está em 0,07 msg/ms e se estabiliza.




(a) Tempo médio de resposta do sistema.



(b) Probabilidade de descarte.



(c) Utilização da camada Cloud.



(d) Vazão do sistema.

Figura 10 – Resultados da variação no tempo de serviço da Cloud.

Com 400 ms, o resultado é semelhante, porém inferior, atingindo 0,03 ms quando a AR está em 0,03 msg/ms.

Embora seja geralmente assumido que tempos de processamento mais longos resultem em tempos totais maiores de processamento, resposta, utilização e vazão, uma análise detalhada do desempenho em diferentes tempos de processamento fornece informações para a otimização. Por exemplo, caso se espere um aumento significativo no tempo de processamento em determinados momentos ou com volumes específicos de trabalho, medidas podem ser tomadas para gerenciar essa carga, como a alocação de recursos adicionais.

8 Conclusão

Este estudo propôs um modelo SPN desenvolvido para analisar o desempenho de um aviário inteligente integrado com computação em Edge, Fog e Cloud. Ao permitir o ajuste de 16 parâmetros distintos, o modelo oferece flexibilidade para avaliar diversos cenários, fornecendo informações sobre métricas de desempenho, como MRT, utilização de recursos, DP e TP. A análise destacou a importância de uma configuração eficaz da camada Cloud, uma vez que ela influencia diretamente o desempenho geral do aviário inteligente. A análise de sensibilidade, que considera as diferentes camadas arquiteturais, contribui para uma compreensão mais profunda das interações entre as variáveis e de como elas afetam o comportamento do sistema. Essa capacidade é essencial para identificar tanto gargalos potenciais quanto oportunidades de otimização. Além disso, a flexibilidade do modelo e os aprimoramentos recentes, incluindo a análise de sensibilidade, possibilitam uma exploração aprofundada da arquitetura do sistema. Ao examinar diferentes configurações da nuvem, o estudo evidencia a importância de equilibrar os recursos entre as camadas de computação Edge, Fog e Cloud. Esse equilíbrio é fundamental para garantir desempenho e confiabilidade ideais, especialmente em ambientes industriais, como granjas inteligentes. Para trabalhos futuros, sugere-se expandir esta análise com cenários adicionais com Edge e Fog para aprofundar o entendimento sobre o comportamento do sistema. Isso permitirá não apenas refinar o modelo proposto, mas também explorar sua aplicação em outros contextos de automação industrial, gerando conhecimentos para otimizar o desempenho, a escalabilidade e a eficiência de sistemas agrícolas baseados em IoT.

9 Publicações

1. **Barbosa, V.**, Arthur, S., Nelson, L., Brito, C., Feitosa, L., Pereira, P., Maciel, P., Nguyen, T. A., Silva, F. A. *Performance Evaluation of IoT-Based Industrial Automation Using Edge, Fog, and Cloud Architectures*. Journal of Network and Systems Management, v. 33, p. 15, 2025.
2. Araújo, I., **Barbosa, V.**, Nelson, L., Guilherme, L., Brito, C., Fé, I., Lopes, L., Andrade, E., Leão, E., Silva, F. A. *Assessing the performance of a fault tolerant LoRaWAN architecture with a focus on the sensor layer and data retransmission strategy*. Cluster Computing, v. 28, p. 275, 2025.
3. Feitosa, L., **Barbosa, V.**, Arthur, S., Nelson, L., Fé, I., Guilherme, L., Callou, G., Carvalho, J., Leão, E., Nguyen, T. A., Rego, P., Silva, F. A. *A comprehensive performance evaluation of container migration strategies*. Computing, v. 107, p. 1–39, 2025.
4. Feitosa, L., **Barbosa, V.**, Bittencourt, L., Oliveira, F. M. C., Reis Junior, J. V., Silva, F. A. *Entregas Aéreas por Drones: Uma Avaliação de Desempenho Considerando Colisões e Logística de Reparo*. In: Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos (SBRC), 2025.
5. Macedo, J. R. L., **Barbosa, V.**, Feitosa, L., Rocha Filho, G. P., Meneguette, R. I., Nelson, L., Silva, F. A. *Avaliação de Desempenho de Redes Veiculares Ad Hoc com RSUs e Filas de Prioridade*. In: Workshop de Computação Urbana (CoUrb) 2025.
6. Alves, M. O., Nelson, L., Arthur, S., **Barbosa, V.**, Guilherme, L., Feitosa, L., Righi, R., Silva, F. A. *Análise de Desempenho e Planejamento de Capacidade em Arquiteturas MQTT para Aplicações IoT*. In: Workshop em Desempenho de Sistemas Computacionais e de Comunicação (WPerformance), 2025.
7. Alves, M., Wanderlei, J., **Barbosa, V.**, Sabino, A., Lima, L. N., Feitosa, L., Clua, E., Silva, F. A. *Computational Capacity Planning for Running Multiplayer Games on Cloud and Fog Infrastructures*. In: Simpósio Brasileiro de Jogos e Entretenimento Digital (SBGAMES), 2025.
8. Arthur, S., Nelson, L., **Barbosa, V.**, Freitas, L., Feitosa, L., Caetano, M. F., Barreto, P. S., Silva, F. A. *Arquitetura Distribuída para Monitoramento de Incêndios: Uma Abordagem com Redes de Petri Estocásticas*. In: Workshop de Computação Aplicada à Gestão do Meio Ambiente e Recursos Naturais (WCAMA), 2025.

9. Guilherme, L., Araújo, I., **Barbosa, V.**, Alves, M. O., Feitosa, L., Rego, P. A. L., Silva, F. A. *Elasticidade de Containers em VANETs: Uma Estratégia de Sustentabilidade Energética em RSUs*. In: Workshop de Computação Aplicada à Gestão do Meio Ambiente e Recursos Naturais (WCAMA), 2025.
10. Lopes, L., Araújo, J. M., Nelson, L., **Barbosa, V.**, Arthur, S., Guilherme, L., Feitosa, L., Rocha Filho, G. P., Silva, F. A. *Avaliação de Dependabilidade e Análise de Sensibilidade de um Sistema de Cuidado Inteligente para Idosos*. In: Seminário Integrado De Software e Hardware (SEMISH), 2025.
11. Araújo, J. M., Lopes, L. S., Nelson, L., **Barbosa, V.**, Arthur, S., Feitosa, L., Delicato, F., Nguyen, T. A., Silva, F. A. *Optimizing Intelligent Camera Surveillance in Smart Buildings: An SPN-based Edge-Fog Analysis*. In: Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos (SBRC), 2025.
12. J. W. Rocha, E. Gomes, **V. Barbosa**, A. Sabino, L. N. Lima, G. Callou, F. A. Silva, E. Choi, T. A. Nguyen, D. Min, and J.-W. Lee. *Enhancing data harvesting systems: performance quantification of agricultural cloud-edge-sensor networks using queueing theory*. ICT Express, 2025.
13. L. S. Lopes, J. M. Araújo, L. N. Lima, **V. Barbosa**, A. Sabino, L. G. Silva, L. Feitosa, G. P. Rocha Filho, and F. A. Silva. *Performance evaluation of a camera surveillance system in smart buildings using queuing models*. Journal of Internet Services and Applications, 2025.
14. Nelson, L., Arthur, S., **Barbosa, V.**, Feitosa, L., Brito, C., Araújo, J., Silva, F. A. *Dependability analysis and disaster recovery measures in smart hospital systems*. Journal of Reliable Intelligent Environments, v. 10, p. 1–17, 2024.
15. Araújo, G., **Barbosa, V.**, Nelson, L., Arthur, S., Brito, C., Fé, I., Rego, P., Choi, E., Min, D., Nguyen, T. A., Silva, F. A. *Energy Consumption in Microservices Architectures: A Systematic Literature Review*. IEEE Access, v. 4, p. 1–1, 2024.
16. **Barbosa, V.**, Arthur, S., Nelson, L., Brito, C., Feitosa, L., Andrade, E., Silva, F. A. *Dependability Evaluation of a Smart Poultry Monitoring System with Disaster Recovery Mechanism*. Journal of the Brazilian Computer Society, v. 30, p. 252–263, 2024.
17. Brito, C., **Barbosa, V.**, Nelson, L., Rocha, J. W., Araújo, J. M., Lopes, L., Rego, P. A. L., Sales, M., Callou, G., Fé, I., Silva, F. A. *Performance evaluation of a video surveillance system using stochastic petri nets for license plate detection on highways*. Journal of Reliable Intelligent Environments, v. 10, p. 1–12, 2024.

18. Silva, F. A., **Barbosa, V.**, Nelson, L., Arthur, S., Rego, P. A. L., Bittencourt, L., Lee, J. W., Min, D., Nguyen, T. A. *Efficient Strategies for Unmanned Aerial Vehicle Flights: Analyzing Battery Life and Operational Performance in Delivery Services using Stochastic Models*. IEEE Access, v. 1, p. 1–14, 2024.
19. Silva, F. A., **Barbosa, V.**, Arthur, S., Nelson, L., Rego, P., Bittencourt, L. *Entregas Aéreas por Drones Cooperativos: Uma Avaliação de Desempenho Considerando Pontos de Recarga de Bateria*. In: Seminário Integrado De Software e Hardware (SEMISH) 2024, v. 51, p. 205–216.
20. Feitosa, L., **Barbosa, V.**, Arthur, S., Nelson, L., Fé, I., Silva, B., Silva, F. A. *Uma Comparação de Múltiplas Políticas de Migração de Contêineres Suportadas pela Ferramenta CRIU*. In: Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos (SBRC) 2024, p. 742–755.
21. Cardoso, I., Brito, C., **Barbosa, V.**, Nogueira, B., Choi, E., Nguyen, T. A., Min, D., Lee, J. W., Silva, F. A. *Urban Advanced Mobility Dependability: A Model-Based Quantification on Vehicular Ad Hoc Networks with Virtual Machine Migration*. Sensors, v. 23, p. 9485, 2023.

Referências

- ABBA, S. et al. Design and performance evaluation of a low-cost autonomous sensor interface for a smart iot-based irrigation monitoring and control system. *Sensors*, MDPI, v. 19, n. 17, p. 3643, 2019. Citado 2 vezes nas páginas 18 e 20.
- AHMAD, I. et al. Intelligent plant monitoring system via iot and fuzzy system. In: *2021 IEEE 7th International Conference on Smart Instrumentation, Measurement and Applications (ICSIMA)*. [S.l.: s.n.], 2021. p. 123–127. Citado 2 vezes nas páginas 19 e 20.
- AI, Y.; PENG, M.; ZHANG, K. Edge computing technologies for internet of things: a primer. *Digital Communications and Networks*, Elsevier, v. 4, n. 2, p. 77–86, 2018. Citado na página 12.
- ALHARBI, H. A.; ALDOSSARY, M. Energy-efficient edge-fog-cloud architecture for iot-based smart agriculture environment. *IEEE Access*, v. 9, p. 110480–110492, 2021. Citado na página 14.
- ANTONY, J. *Design of experiments for engineers and scientists*. [S.l.]: Elsevier, 2014. Citado na página 16.
- ASSESSMENT of the World's \$487 Billion Poultry Market (2023-2027). 2023. <https://www.prnewswire.com/news-releases/assessment-of-the-worlds-487-billion-poultry-market-2023-2027-301862969.html>. Acesso em: 1 maio 2025. Citado na página 12.
- ASTILL, J. et al. Smart poultry management: Smart sensors, big data, and the internet of things. *Computers and Electronics in Agriculture*, v. 170, p. 105291, 2020. ISSN 0168-1699. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0168169918316363>>. Citado 2 vezes nas páginas 12 e 14.
- ASTILL, J. et al. Smart poultry management: Smart sensors, big data, and the internet of things. *Computers and Electronics in Agriculture*, Elsevier, v. 170, p. 105291, 2020. Citado 2 vezes nas páginas 13 e 21.
- AZAD, S.; PADHY, S.; DASH, S. A case study on the multi-hopping performance of iot network used for farm monitoring. *Automatic Control and Computer Sciences*, Springer, v. 57, n. 1, p. 70–80, 2023. Citado 2 vezes nas páginas 19 e 20.
- BRITO, C. et al. Offloading data through unmanned aerial vehicles: a dependability evaluation. *Electronics*, MDPI, v. 10, n. 16, p. 1916, 2021. Citado na página 15.
- BUYYA, R.; BROBERG, J.; GOSCINSKI, A. M. *Cloud computing: Principles and paradigms*. [S.l.]: John Wiley & Sons, 2010. Citado na página 15.
- CAMPOLONGO, F.; TARANTOLA, S.; SALTELLI, A. Tackling quantitatively large dimensionality problems. *Computer Physics Communication*, Institute Jbr Systems, Informatics and Safety. Joint Research Centre of the European Commission, v. 117, n. 1, p. 75–85, 1999. Citado na página 17.

- CHEN, L.; HA, W. Reliability prediction and qos selection for web service composition. *International Journal of Computational Science and Engineering*, Inderscience Publishers (IEL), v. 16, n. 2, p. 202–211, 2018. Citado na página 15.
- CHOUKIDAR, G. A.; DAWANDE, N. Smart poultry farm automation and monitoring system. In: IEEE. *2017 International Conference on Computing, Communication, Control and Automation (ICCUBEA)*. [S.l.], 2017. p. 1–5. Citado na página 21.
- EGGS Market Size, Share & Industry Analysis Report, 2024-2032. 2024. <https://www.fortunebusinessinsights.com/eggs-market-108483>. Acesso em: 1 maio 2025. Citado na página 12.
- FIROUZI, F.; FARAHANI, B.; MARINŠEK, A. The convergence and interplay of edge, fog, and cloud in the ai-driven internet of things (iot). *Information Systems*, Elsevier, v. 107, p. 101840, 2022. Citado na página 14.
- GIRAULT, C.; VALK, R. *Petri nets for systems engineering: a guide to modeling, verification, and applications*. [S.l.]: Springer Science & Business Media, 2013. Citado na página 15.
- GUILLÉN, M. A. et al. Performance evaluation of edge-computing platforms for the prediction of low temperatures in agriculture using deep learning. *The Journal of Supercomputing*, Springer, v. 77, p. 818–840, 2021. Citado 2 vezes nas páginas 19 e 20.
- HUO, D. et al. Towards smart farming: Simulation framework to exploit network connectivity for end-to-end data transmission. In: *2022 14th International Conference on Software, Knowledge, Information Management and Applications (SKIMA)*. [S.l.: s.n.], 2022. p. 276–279. Citado 2 vezes nas páginas 19 e 20.
- ILZARBE, L. et al. Practical applications of design of experiments in the field of engineering: a bibliographical review. *Quality and Reliability Engineering International*, v. 24, n. 4, p. 417–428, jun 2008. ISSN 0748-8017. Disponível em: <<https://onlinelibrary.wiley.com/doi/10.1002/qre.909>>. Citado na página 28.
- ISLAM, M. M. et al. Smart poultry farm incorporating gsm and iot. In: *2019 International Conference on Robotics, Electrical and Signal Processing Techniques (ICREST)*. [S.l.: s.n.], 2019. p. 277–280. Citado na página 12.
- ISLAM, M. M. et al. Smart poultry farm incorporating gsm and iot. In: IEEE. *2019 International Conference on Robotics, Electrical and Signal Processing Techniques (ICREST)*. [S.l.], 2019. p. 277–280. Citado na página 14.
- ISLAM, M. M. et al. Smart poultry farm incorporating gsm and iot. In: *2019 International Conference on Robotics, Electrical and Signal Processing Techniques (ICREST)*. [S.l.: s.n.], 2019. p. 277–280. Citado na página 21.
- JUAN, Z.; YANBIN, L.; NENGQUAN, G. Performance evaluation system. In: . [S.l.: s.n.], 2017. Citado na página 16.
- KLEIJNEN, J. P. Sensitivity analysis and optimization in simulation: design of experiments and case studies. In: IEEE. *Winter Simulation Conference Proceedings, 1995*. [S.l.], 1995. p. 133–140. Citado na página 16.

- KUMAR, N. et al. Impact of iot based autonomous farming equipment on crop culture and management in the agricultural sector. In: *2022 International Conference on Edge Computing and Applications (ICECAA)*. [S.l.: s.n.], 2022. p. 669–675. Citado 2 vezes nas páginas 18 e 20.
- LITTLE, J. D. A proof for the queuing formula: $L = \lambda w$. *Operations research*, INFORMS, v. 9, n. 3, p. 383–387, 1961. Citado na página 26.
- MACIEL, P. et al. Mercury: Performance and dependability evaluation of systems with exponential, expolynomial, and general distributions. In: IEEE. *2017 IEEE 22nd Pacific Rim international symposium on dependable computing (PRDC)*. [S.l.], 2017. p. 50–57. Citado na página 32.
- MAHMUD, R.; RAMAMOHANARAO, K.; BUYYA, R. Latency-aware application module management for fog computing environments. *ACM Transactions on Internet Technology (TOIT)*, ACM New York, NY, USA, v. 19, n. 1, p. 1–21, 2018. Citado na página 13.
- MALIK, A. W. et al. Leveraging fog computing for sustainable smart farming using distributed simulation. *IEEE Internet of Things Journal*, v. 7, n. 4, p. 3300–3309, 2020. Citado 2 vezes nas páginas 18 e 20.
- MILES, B. et al. A study of lorawan protocol performance for iot applications in smart agriculture. *Computer Communications*, v. 164, p. 148–157, 2020. ISSN 0140-3664. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0140366420319575>>. Citado 2 vezes nas páginas 19 e 20.
- MULTIMIX, B. A. *Avicultura Brasileira: Passado, Presente e Futuro*. 2022. <https://agrocereismultimix.com.br/blog/avicultura-brasileira-passado-presente-e-futuro/>. Acesso em: 19 outubro 2023. Citado na página 12.
- MULYA, M. A. et al. Field trial and performance evaluation of iot poultry farm monitoring system. *International Journal of Electronics and Telecommunications*, v. 70, 2024. Citado 2 vezes nas páginas 18 e 20.
- MURATA, T. Petri nets: Properties, analysis and applications. *Proceedings of the IEEE*, IEEE, v. 77, n. 4, p. 541–580, 1989. Citado na página 15.
- OJO, M. O.; ADAMI, D.; GIORDANO, S. Network performance evaluation of a lora-based iot system for crop protection against ungulates. In: *2020 IEEE 25th International Workshop on Computer Aided Modeling and Design of Communication Links and Networks (CAMAD)*. [S.l.: s.n.], 2020. p. 1–6. Citado 2 vezes nas páginas 18 e 20.
- OLIVEIRA, F. et al. Dependability evaluation of a smart poultry house: Addressing availability issues through the edge, fog, and cloud computing. *IEEE Transactions on Industrial Informatics*, IEEE, 2023. Citado 3 vezes nas páginas 14, 15 e 21.
- PARK, S. et al. Performance evaluation of containerized systems before and after using kubernetes for smart farm visualization platform based on lorawan. In: *2022 Sixth IEEE International Conference on Robotic Computing (IRC)*. [S.l.: s.n.], 2022. p. 44–47. Citado 2 vezes nas páginas 18 e 20.

- PEIXOTO, M. L. M.; GENEZ, T. A.; BITTENCOURT, L. F. Hierarchical scheduling mechanisms in multi-level fog computing. *IEEE Transactions on services computing*, IEEE, v. 15, n. 5, p. 2824–2837, 2021. Citado na página 12.
- PINHEIRO, T. et al. The mercury environment: a modeling tool for performance and dependability evaluation. In: *Intelligent Environments 2021*. [S.l.]: IOS Press, 2021. p. 16–25. Citado na página 32.
- POOJA, S. et al. Application of mqtt protocol for real time weather monitoring and precision farming. In: *2017 International Conference on Electrical, Electronics, Communication, Computer, and Optimization Techniques (ICEECCOT)*. [S.l.: s.n.], 2017. p. 1–6. Citado 2 vezes nas páginas 18 e 20.
- RODRIGUES, L. et al. Modelo estocástico para avaliação de disponibilidade de hospitais inteligentes. In: SBC. *Anais do XIX Workshop em Desempenho de Sistemas Computacionais e de Comunicação*. [S.l.], 2020. p. 145–156. Citado na página 15.
- RODRIGUES, L. et al. Performance evaluation of smart cooperative traffic lights in vanets. *International Journal of Computational Science and Engineering*, Inderscience Publishers (IEL), v. 24, n. 3, p. 276–289, 2021. Citado na página 27.
- SABO, S.; UMARU, A. M.; YUSUF, L. A. Smart iot-based broiler room controller: Design, implementation, performance evaluation, and optimization. *Journal of Science and Technology*, v. 30, n. 2, 2025. Citado 2 vezes nas páginas 18 e 20.
- SANTOS, G. L. et al. Analyzing the availability and performance of an e-health system integrated with edge, fog and cloud infrastructures. *Journal of Cloud Computing*, SpringerOpen, v. 7, n. 1, p. 1–22, 2018. Citado na página 15.
- SANTOS, L. et al. Data processing on edge and cloud: a performability evaluation and sensitivity analysis. *Journal of Network and Systems Management*, Springer, v. 29, n. 3, p. 27, 2021. Citado na página 17.
- SHUKLA, S. et al. Improving latency in internet-of-things and cloud computing for real-time data transmission: a systematic literature review (slr). *Cluster Computing*, Springer, p. 1–24, 2021. Citado na página 15.
- SILVA, F. A.; FÉ, I.; GONÇALVES, G. Stochastic models for performance and cost analysis of a hybrid cloud and fog architecture. *The Journal of Supercomputing*, Springer, v. 77, p. 1537–1561, 2021. Citado na página 12.
- SILVA, F. A. et al. Mobile cloud performance evaluation using stochastic models. *IEEE Transactions on Mobile Computing*, v. 17, n. 5, p. 1134–1147, 2018. Citado na página 15.
- SO-IN, C.; POOLSANGUAN, S.; RUJIRAKUL, K. A hybrid mobile environmental and population density management system for smart poultry farms. *Computers and Electronics in Agriculture*, Elsevier, v. 109, p. 287–301, 2014. Citado na página 21.
- YASCARIBAY, G. et al. Performance evaluation of communication systems used for internet of things in agriculture. *Agriculture*, MDPI, v. 12, n. 6, p. 786, 2022. Citado 2 vezes nas páginas 19 e 20.

YATSYSHYN, V. et al. Technology of relational database management systems performance evaluation during computer systems design. v. 109, n. 1, p. 54–65, 2023. Citado na página [16](#).



**TERMO DE AUTORIZAÇÃO PARA PUBLICAÇÃO DIGITAL NA BIBLIOTECA
“JOSÉ ALBANO DE MACEDO”**

Identificação do Tipo de Documento

- () Tese
() Dissertação
(x) Monografia
() Artigo

Eu, Vandirleya Barbosa da Costa,
autorizo com base na Lei Federal nº 9.610 de 19 de Fevereiro de 1998 e na Lei nº 10.973 de
02 de dezembro de 2004, a biblioteca da Universidade Federal do Piauí a divulgar,
gratuitamente, sem ressarcimento de direitos autorais, o texto integral da publicação
Avaliação de Desempenho de um Aviário Inteligente com Arquitetura Edge-Fog-
Cloud

de minha autoria, em formato PDF, para fins de leitura e/ou impressão, pela internet a título
de divulgação da produção científica gerada pela Universidade.

Picos-PI, 28 de junho de 2025.

Documento assinado digitalmente
VANDIRLEYA BARBOSA DA COSTA
Data: 30/06/2025 15:07:15-0300
Verifique em <https://validar.iti.gov.br>

Assinatura