



Universidade Federal do Ceará
Departamento de Engenharia de Teleinformática
Programa de Pós-Graduação em Engenharia de Teleinformática

Dissertação de Mestrado

Análise de Sobrevivência na Modelagem do Tempo de Vida de Redes de Sensores sem Fio

Rodrigo Teles Hermeto

Fortaleza-Ceará

Agosto de 2014

Rodrigo Teles Hermeto

Análise de Sobrevivência na Modelagem do Tempo de Vida de Redes de Sensores sem Fio

Dissertação submetida à coordenação do Programa de Pós-Graduação em Engenharia de Teleinformática da Universidade Federal do Ceará como requisito parcial para a obtenção do grau de Mestre em Engenharia de Teleinformática

Prof. Dr. Danielo Gonçalves Gomes
Prof. Dr. Juvêncio Santos Nobre

Fortaleza-Ceará

Agosto de 2014

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca de Pós-Graduação em Engenharia - BPGE

-
- H474a Hermeto, Rodrigo Teles.
Análise de sobrevivência na modelagem do tempo de vida de redes de sensores sem fio / Rodrigo Teles Hermeto. – 2014.
62 f. : il. color. , enc. ; 30 cm.
- Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia de Teleinformática, Fortaleza, 2014.
Área de concentração: Sinais e Sistemas.
Orientação: Prof. Dr. Danielo Gonçalves Gomes.
Coorientação: Prof. Dr. Juvêncio Santos Nobre.
1. Teleinformática. 2. Sistemas de comunicação sem fio. 3. Confiabilidade. I. Título.



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE TELEINFORMÁTICA
CAMPUS DO PICI, CAIXA POSTAL 6007 CEP 60.738-640
FORTALEZA – CEARÁ - BRASIL
FONE (+55) 85 3366-9467 – FAX (+55) 85 3366-9468

RODRIGO TELES HERMETO

**ANÁLISE DE SOBREVIVÊNCIA NA MODELAGEM DO TEMPO DE VIDA DE
REDES DE SENSORES SEM FIO**

Dissertação submetida à Coordenação do Programa de Pós-Graduação em Engenharia de Teleinformática, da Universidade Federal do Ceará, como requisito parcial para a obtenção do grau de Mestre em Engenharia de Teleinformática.
Área de concentração: Sinais e Sistemas.

Aprovada em: 27/08/2014.

BANCA EXAMINADORA

Prof. Dr. Danielo Gonçalves Gomes (Orientador)
Universidade Federal do Ceará

Prof. Dr. Juvêncio Santos Nobre
Universidade Federal do Ceará

Prof. Dr. José Neuman de Souza
Universidade Federal do Ceará

Prof. Dr. Omar Carvalho Branquinho
Pontifícia Universidade Católica de Campinas

A meus pais, João e Mariana, que me deram a vida, me criaram com todo amor e carinho e me ensinaram a ser uma pessoa de bem e que busca sempre a justiça. A Alice, minha esposa, que sempre me deu apoio nas horas mais difíceis e que se mostra a cada dia uma das minhas melhores escolhas de vida.

Agradecimentos

Aos meus pais, João e Mariana, peças fundamentais na minha vida, que sempre me transmitiram os seus melhores valores e contribuíram para a minha formação como ser humano.

À Alice, pelo amor, paciência, compreensão e companheirismo dedicados à mim de forma completa. Sem ela não teria conseguido suportar o stress durante o mestrado.

Aos meus sogros, dona Fátima e seu Pádua, por terem aberto as portas de sua casa desde sempre, principalmente nas horas de maior necessidade, e por sempre terem me tratado com bastante carinho.

Ao meu orientador Danielo, que me recebeu desde a primeira vez na sua sala com bastante simpatia e me propôs esse projeto desafiador que me fez buscar respostas e soluções, me ensinando a ter pró-atividade. Agradeço também por tirar minhas dúvidas, me dar sugestões e indicar os caminhos pelos quais eu deveria seguir.

Ao meu coorientador Juvêncio, pelas palavras de apoio nas horas certas, pela enorme paciência e pelas ótimas ideias sugeridas.

À professora Rossana, por ter me recebido tão bem no GREat.

Aos professores Fernando Trinta e Miguel, por terem cedido as suas salas para que eu pudesse realizar os experimentos deste trabalho.

Ao professor Neuman, por ter emprestado todos os dispositivos utilizados nos experimentos.

Ao casal nota mil, Reinaldo e Carina, que me ajudaram bastante na realização deste trabalho, dando boas ideias e sugestões.

Ao professor Fernando Parente, pelas ideias e críticas construtivas.

À Atslands, pela parceria no primeiro ano do Mestrado, na qual publicamos um artigo premiado.

Ao meu amigo Douglas, por todas as figuras por ele desenhadas e pela parceria durante boa parte do Mestrado.

Ao meu amigo Paulo Artur, por todas as correções de português realizadas durante o Mestrado e pelas pilhas que se encarregou de jogar fora.

Ao meu amigo Danilo, por ter me emprestado seu notebook, para que eu pudesse utilizá-lo nos experimentos.

Aos meus amigos Sérgio, Ítalo "meu chapa", Vanessa e Edigleison, pelas contribuições

e força durante o Mestrado.

Ao meus gerentes Bruno Saboia, Danyel Perote, Rute, e meu líder técnico Wellington, pela flexibilidade dos meus horários quando mais precisei.

E a todos meus amigos que, de alguma forma, contribuíram para a realização deste trabalho.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela bolsa concedida, possibilitando a dedicação exclusiva para a execução do projeto de pesquisa.

Twenty years from now you will be more disappointed by the things that you didn't do than by the ones you did so. So throw off the bowlines. Sail away from the safe harbor. Catch the trade winds in your sails. Explore. Dream. Discover. (Mark Twain)

Resumo

As Redes de Sensores Sem Fio (RSSF) são exemplos de Resource-Constrained Networks (RCNs) nas quais recursos de processamento, armazenamento e energia são limitados. A partir do momento em que uma RSSF típica entra em funcionamento, decorre-se um intervalo de tempo, conhecido como tempo de vida da rede, durante o qual os nós sensores executam operações de sensoriamento, processamento e comunicação, consumindo energia de suas fontes (e.g. pilhas) até valores mínimos de carga que os mantêm em operação. Estimar *a priori* a estrutura probabilística/estocástica do tempo de vida de uma RSSF antes da sua implantação fornece meios de elaborar estratégias de manutenção de forma a maximizar seu tempo de vida e de garantir que a rede sobreviverá tempo suficiente para cumprir seu objetivo. Assim sendo, esta dissertação aborda os modelos Exponencial, Weibull e Log-Normal, comumente utilizados em estudos de Análise de Sobrevivência, para obter estimativas do tempo de sobrevivência de uma rede real a partir dos tempos de vida de seus nós observados em simulação. Nossa hipótese de base é a de que a Análise de Sobrevivência pode melhorar a acurácia da estimativa do tempo de vida de uma RSSF e, por conseguinte, o seu planejamento operacional. Aqui propomos respostas a três questões em aberto na literatura: (i) quantos nós sensores irão sair de operação durante o tempo de vida de uma RSSF (ii) em qual intervalo de tempo a maior parte dos nós vai sair de operação (iii) por quanto tempo a rede permanecerá em funcionamento.

Palavras-chave: Rede de Sensores sem Fio, Análise de Sobrevivência, Modelos Probabilísticos, Inferência, Tempo de Vida.

Abstract

Wireless Sensor Networks (WSN) are examples of Resource-Constrained Networks (RCNs) in which processing resources, storage and energy are limited. From the moment a typical WSN goes into operation, the sensor nodes begin to perform operations like sensing, processing and communicating, consuming the stored energy in their batteries until it ends completely, a situation that is characterized like the death of the devices and consequently the network. Knowing a priori the expected lifetime of a WSN before deploying it, enables the development of maintenance strategies to maximize its lifespan and ensure that it survives enough time to accomplish its goal. Therefore, we propose in this work the use of Exponential, Weibull and Log-Normal models, which are commonly used in studies of Survival Analysis, to infer survival statistics of a real network from the lifespans of its nodes observed in simulation. Our hypothesis is that the Survival Analysis may improve the accuracy of estimating the lifetime of a WSN and, consequently, their operational planning. This work proposes answers to three questions which are open in the literature: (i) how many sensor nodes will die during the lifetime of a WSN (ii) in which time period most of the nodes will die (iii) for how long network will remain operational.

Keywords: Wireless Sensor Network, Survival Analysis, Probabilistic Models, Lifetime Inference.

Lista de ilustrações

| | |
|---|----|
| Figura 1 – Censuras. Círculo representa que o indivíduo morreu. Quadrado representa que o indivíduo permaneceu vivo. Triângulo representa morte por outros motivos não relacionados ao experimento. Fonte: (COLOSIMO; GIOLO, 2006). | 19 |
| Figura 2 – Exemplos de duas funções densidade. | 20 |
| Figura 3 – Diferentes funções de sobrevivência. | 21 |
| Figura 4 – Diferentes funções de risco instantâneas. | 23 |
| Figura 5 – Rede implantada com sorvedouro posicionado na extremidade. | 32 |
| Figura 6 – Delineamento. | 33 |
| Figura 7 – Rede piloto utilizada para calibrar o simulador. | 34 |
| Figura 8 – Rede do cenário #1. | 36 |
| Figura 9 – Arquitetura da rede do cenário #1. | 37 |
| Figura 10 – Rede do cenário #2. | 37 |
| Figura 11 – Arquitetura da rede do cenário #2. | 38 |
| Figura 12 – Estimativas obtidas a partir do modelo exponencial para diferentes definições de tempo de vida (a. 10%, b. 51% e c. 90%). | 41 |
| Figura 13 – Comparação entre a função estimada pelo modelo exponencial e pelo método não-paramétrico de Kaplan-Meier. | 41 |
| Figura 14 – Estimativas obtidas a partir do modelo Weibull para diferentes definições de tempo de vida (a. 10%, b. 51% e c. 90%). | 42 |
| Figura 15 – Estimativas das funções de sobrevivência obtidas a partir do modelo Weibull para a rede com 1 sorvedouro (ajustes a. ruim, b. intermediário e c. bom). | 43 |
| Figura 16 – Estimativas das funções densidade obtidas a partir do modelo Weibull para a rede com 1 sorvedouro (ajustes a. ruim, b. intermediário e c. bom). | 44 |
| Figura 17 – Estimativas das funções de risco obtidas a partir do modelo Weibull para a rede com 1 sorvedouro (ajustes a. ruim, b. intermediário e c. bom). | 45 |
| Figura 18 – Estimativas inferidas a partir do modelo log-normal para diferentes definições de tempo de vida (a. 10%, b. 51% e c. 90%). | 45 |
| Figura 19 – Comparação entre as funções de sobrevivência estimadas pelo modelo log-normal e da rede real (ajustes a. ruim, b. intermediário e c. bom). | 46 |
| Figura 20 – Comparação entre as funções densidade estimadas pelo modelo log-normal e da rede real (ajustes a. ruim, b. intermediário e c. bom). | 47 |
| Figura 21 – Comparação entre as funções de risco estimadas pelo modelo log-normal e da rede real (ajustes a. ruim, b. intermediário e c. bom). | 47 |

| | |
|--|----|
| Figura 22 – Estimativas obtidas a partir do modelo exponencial para rede com 2 sorvedouros para diferentes definições de tempo de vida (a. 10%, b. 51% e c. 90%). | 48 |
| Figura 23 – Comparação entre a função estimada pelo modelo exponencial e não-paramétrico. | 49 |
| Figura 24 – Estimativas inferidas a partir do modelo Weibull para diferentes definições de tempo de vida (a. 10%, b. 51% e c. 90%). | 50 |
| Figura 25 – Estimativas das funções de sobrevivência obtidas a partir do modelo Weibull para a rede com 2 sorvedouros (ajustes a. ruim, b. intermediário e c. bom). | 51 |
| Figura 26 – Estimativas das funções densidade obtidas a partir do modelo Weibull para a rede com 2 sorvedouros (ajustes a. ruim, b. intermediário e c. bom). | 51 |
| Figura 27 – Estimativas das funções de risco obtidas a partir do modelo Weibull para a rede com 2 sorvedouros (ajustes a. ruim, b. intermediário e c. bom). | 52 |
| Figura 28 – Estimativas obtidas a partir do modelo log-normal para diferentes definições de tempo de vida (a. 10%, b. 51% e c. 90%). | 53 |
| Figura 29 – Estimativas das funções de sobrevivência obtidas a partir do modelo log-normal para a rede com 2 sorvedouros (ajustes a. ruim, b. intermediário e c. bom). | 53 |
| Figura 30 – Estimativas das funções densidade obtidas a partir do modelo log-normal para a rede com 2 sorvedouros (ajustes a. ruim, b. intermediário e c. bom). | 54 |
| Figura 31 – Estimativas das funções de risco obtidas a partir do modelo log-normal para a rede com 2 sorvedouros (ajustes a. ruim, b. intermediário e c. bom). | 54 |

Lista de tabelas

| | |
|--|----|
| Tabela 1 – Tempos que indicam últimos registros de vida dos nós da rede piloto. . | 34 |
| Tabela 2 – Tempos que indicam últimos registros de vida dos nós da rede do cenário | |
| 1. | 60 |
| Tabela 3 – Tempos que indicam últimos registros de vida dos nós da rede do cenário | |
| 2. | 60 |

Sumário

| | | |
|----------|--|-----------|
| 1 | INTRODUÇÃO | 15 |
| 1.1 | Problemática - Qualificação e Justificativa | 15 |
| 1.2 | Objetivo | 16 |
| 1.3 | Metodologia | 16 |
| 1.4 | Estrutura do documento | 17 |
| 2 | REVISÃO BIBLIOGRÁFICA | 18 |
| 2.1 | Análise de Sobrevivência | 18 |
| 2.2 | Função Densidade de Probabilidade $f(t)$ | 20 |
| 2.3 | Função de Sobrevivência $S(t)$ | 21 |
| 2.4 | Função de Risco Instantânea $h(t)$ | 22 |
| 2.5 | Modelos de Sobrevivência Paramétricos | 23 |
| 2.5.1 | Distribuição Exponencial | 23 |
| 2.5.2 | Distribuição de Weibull | 24 |
| 2.5.3 | Distribuição Log-normal | 24 |
| 2.6 | Método de Máxima Verossimilhança | 25 |
| 2.7 | Estimador de Kaplan-Meier | 25 |
| 2.8 | Áreas e exemplos de aplicação | 26 |
| 2.8.1 | Trabalhos baseados em conectividade | 26 |
| 2.8.2 | Trabalhos baseados em energia | 27 |
| 2.8.3 | Trabalhos baseados na vida útil de componentes | 27 |
| 2.8.4 | Trabalhos baseados segurança | 27 |
| 2.8.5 | Trabalhos baseados no tempo de vida | 27 |
| 2.9 | Resumo do capítulo | 28 |
| 3 | MATERIAL E MÉTODOS | 29 |
| 3.1 | Evento de interesse | 29 |
| 3.2 | Tempo de vida dos nós | 29 |
| 3.3 | Tempo de vida da rede | 30 |
| 3.3.1 | Cálculo do tempo de vida da rede | 30 |
| 3.4 | Modelos paramétricos e não-paramétricos | 31 |
| 3.5 | Ambiente de experimentos | 31 |
| 3.6 | Material | 32 |
| 3.7 | Delineamento - estratégia de estudo | 33 |
| 3.7.1 | Calibração do simulador | 33 |
| 3.7.2 | Simulação | 35 |

| | | |
|------------|---|-----------|
| 3.7.3 | Rede real | 35 |
| 3.7.3.1 | Cenário #1 - Rede com 1 sorvedouro | 36 |
| 3.7.3.2 | Cenário #2 - Rede com 2 sorvedouros | 36 |
| 3.7.4 | Metodologia de análise de sobrevivência | 38 |
| 3.8 | Resumo do capítulo | 39 |
| 4 | RESULTADOS E DISCUSSÕES | 40 |
| 4.1 | Rede com 1 sorvedouro | 40 |
| 4.1.1 | Modelo Exponencial | 40 |
| 4.1.2 | Modelo Weibull | 42 |
| 4.1.3 | Modelo log-normal | 44 |
| 4.2 | Rede com 2 sorvedouros | 48 |
| 4.2.1 | Modelo Exponencial | 48 |
| 4.2.2 | Modelo Weibull | 49 |
| 4.2.3 | Modelo log-normal | 52 |
| 4.3 | Considerações sobre o modelo exponencial | 54 |
| 4.4 | Considerações sobre o modelo Weibull | 55 |
| 4.4.1 | Considerações sobre o modelo log-normal | 55 |
| 4.5 | Resumo do capítulo | 56 |
| 5 | CONCLUSÕES | 57 |
| 5.1 | Contribuições | 57 |
| 5.2 | Produção científica | 57 |
| 5.3 | Estudos Futuros | 58 |
| | Referências | 61 |

1 Introdução

Algumas distribuições probabilísticas têm apresentado bons resultados na modelagem do tempo de vida de produtos industriais (COLOSIMO; GIOLO, 2006). Nesta dissertação, apresentamos um estudo comparativo de três delas aplicadas no domínio das Redes de Sensores sem Fio (RSSF).

Na Seção 1.1, é realizada uma breve qualificação da importância do problema atacado e na Seção 1.2 expomos o objetivo central desta dissertação. Na Seção 1.3, apresentamos a metodologia utilizada e, na Seção 1.4 a estrutura deste documento.

1.1 Problemática - Qualificação e Justificativa

Uma rede de sensores sem fio é composta por objetos inteligentes, i.e. nós equipados com processador, sensores, rádio e uma fonte de energia, implantados em uma área geográfica para monitoramento de um dado fenômeno físico de interesse, por exemplo temperatura, pressão, detecção de movimentos, qualidade do ar, entre outros.

A fonte de energia é recurso crucial dos nós de uma RSSF, pois dela dependem todos os demais. Apesar dos recentes avanços na pesquisa para produção local de energia, como transdutores piezoelétricos, células solares, calor e pressão arterial do corpo humano (SEAH; EU; TAN, 2009), as clássicas e finitas baterias ainda são o tipo de fonte mais comum dos nós sensores.

Ao serem colocados em operação, os nós de uma RSSF consomem a energia armazenada em suas baterias até seu valor limiar de operação. Alguns nós, por sua vez, tendem a se descarregar mais rapidamente que outros, seja por desempenharem papéis de líderes de agrupamentos (ROCHA et al., 2012), de fusão de dados (NAKAMURA; LOUREIRO; FRERY, 2007) ou simplesmente por estarem mais próximos ao sorvedouro (CHENG; CHUAH, 2004).

Em uma ambiente onde a energia é um recurso limitado, o tempo de vida é a métrica mais crítica (DIETRICH; DRESSLER, 2009). É importante saber por quanto tempo uma determinada rede de sensores consegue monitorar o seu entorno, sobretudo quando se trata de um ambiente inóspito ou de difícil acesso. Entretanto, o entendimento do que vem a ser tempo de vida em redes de sensores não é consensual. Dietrich e Dressler (2009), por exemplo, consideram tempo de vida de uma RSSF na perspectiva de conectividade, cobertura e qualidade de serviço (QoS). Estas métricas ainda podem ser subdivididas de forma mais específica, como por exemplo, conectividade associada à morte (i) do primeiro nó (CHANG; TASSIULAS, 2004), (ii) de uma proporção de nós (CERPA;

MEMBER; ESTRIN, 2004) e (iii) de todos os nós (TIAN; AVENUE; GEORGANAS, 2000). Independentemente da abordagem utilizada, notamos na literatura que o tempo de vida em RSSF têm sido usado somente de forma reativa, i.e. após a morte da rede. Entretanto, conhecer o seu tempo de vida *a posteriori* dificulta a realização de manutenções preventivas, como troca de baterias ou reposição de nós.

Objetivando melhorar o planejamento operacional de uma RSSF, propomos nesta dissertação responder, utilizando modelos paramétricos, as seguintes perguntas:

1) *Quantos nós sensores irão morrer durante o tempo de vida de uma RSSF?*

Responder esse questionamento possibilita avaliar como está o balanceamento de carga entre os nós. Se ainda existe uma quantidade relevante de nós vivos (com energia, mas sem comunicação) ao final da vida da rede, talvez seja necessário reavaliar a distribuição de funções ou posicionamento deles. Além disso, acompanhar a proporção de nós ainda vivos ao longo do tempo fornece meios de avaliar se a quantidade de nós é excessiva. Se a rede se mantém viva com, por exemplo, 70% dos nós vivos por um longo tempo, pode ser um indicativo de excesso de nós.

2) *Em qual intervalo de tempo a maior parte dos nós vai morrer?*

De posse dessa informação, é possível planejar os reparos na rede (reposição de nós ou recarga de baterias) que eventualmente possam ser necessários.

3) *Por quanto tempo a rede permanecerá viva?*

Não é interessante implantar uma rede de sensores sem fio para que ela venha a morrer antes de cumprir com seu objetivo. Se uma rede precisa monitorar uma região por um determinado período, conhecer aproximadamente seu tempo de vida, considerando que os nós morrem somente por falta de energia, possibilita saber o quão confiável ela é.

1.2 Objetivo

Testar e avaliar se distribuições probabilísticas comumente utilizadas para modelar tempo de vida são capazes de modelar com precisão ou de forma satisfatória o tempo de vida de redes de sensores sem fio.

1.3 Metodologia

Este é um estudo de associação com interferência, organizado conforme a seguinte estratégia sequencial:

- Encontrar uma distribuição de probabilidade que melhor modele as variações de cargas iniciais das baterias utilizadas pelos nós sensores da rede a ser implantada;

- Simular a rede física utilizando a distribuição de probabilidade encontrada para gerar amostras de cargas aleatórias a serem utilizadas pelos nós da rede simulada;
- Calibrar os modelos probabilísticos a partir dos tempos de vida observados nas simulações;
- Implantar fisicamente a rede de sensores;
- Analisar as previsões obtidas do tempo de vida das redes simulada e real; e
- Discutir os resultados, em especial a qualidade dos ajustes e acurácia das estimativas inferidas a partir de dados obtidos através de simulações.

1.4 Estrutura do documento

No Capítulo 2 é realizado um apanhado dos principais conceitos da Análise de Sobrevivência, destacando trabalhos em diversas áreas do conhecimento, inclusive em redes de sensores sem fio. No Capítulo 3 é apresentada a metodologia proposta nesta dissertação para aplicação da Análise de Sobrevivência no domínio das RSSF. No Capítulo 4, apresentamos os resultados e respectivas discussões. Por fim, no Capítulo 5, apresenta-se uma síntese das principais conclusões e contribuições, apontando perspectivas de trabalhos futuros.

2 Revisão Bibliográfica

Neste capítulo são apresentados os conceitos introdutórios de Análise de Sobrevida. Primeiramente, apresentamos de forma resumida alguns conceitos de Análise de Sobrevida. Em seguida, são introduzidas as principais funções que são normalmente utilizadas na Análise de Sobrevida, são elas: Função Densidade de Probabilidade, Função de Sobrevida e Função de Risco. Em seguida, as distribuições de probabilidade utilizadas neste trabalho são apresentadas, são elas: Distribuição exponencial, Weibull e log-normal. Em seguida, o método de máxima verossimilhança é apresentado. Após isso, o estimador não-paramétrico de Kaplan-Meier é apresentado. Por fim, são apresentadas aplicações da análise de sobrevida em diversas áreas do conhecimento.

2.1 Análise de Sobrevida

Análise de Sobrevida é um método estatístico utilizado para estudo do tempo de ocorrência de um evento de interesse (falha, morte, reincidência de doença, e etc) a fim de se estimar a probabilidade de sobrevida em um determinado instante de tempo. Assim, o estudo da Análise de Sobrevida é focado na previsão da probabilidade de resposta, sobrevida, ou tempo de vida médio, comparando as distribuições de sobrevida de um conjunto de indivíduos participantes de um determinado experimento.

Idealmente, nos experimentos de Análise de Sobrevida todos os tempos para o evento de interesse são devidamente conhecidos (Figura 1(a)). Entretanto, esses tempos são desconhecidos em certos experimentos em que nem todos indivíduos apresentaram o comportamento esperado ao final desses. No domínio das redes de sensores sem fio, quando não há mais conectividade entre os nós e o sorvedouro, o que caracteriza morte da rede, ainda podem existir nós vivos, porém sem conectividade, dispersos no ambiente. Dessa maneira, os seus tempos de vida são desconhecidos. Na ocorrência dessa situação, diz-se que os dados, ou tempos, são censurados.

Em Colosimo e Giolo (2006), são apresentados os três tipos de censura de dados. Os do tipo I (Figura 1(b)), ocorrem em experimentos cujo, ao término desses, ainda existem indivíduos vivos. O tipo II (Figura 1c), ocorrem em experimentos cujo é definido, inicialmente, um número pré-determinado de falhas ou mortes e, quando esse número for alcançado, os tempos de vida dos indivíduos que ainda não morreram são desconhecidos e maiores do tempo observado no instante em que último indivíduo avaliado morreu. O tipo III (Figura 1), por sua vez, quando um indivíduo é retirado do experimento após a ocorrência de uma falha que não está relacionada diretamente com o experimento de sobrevida. Essas censuras se caracterizam como censura à direita, pois o tempo de

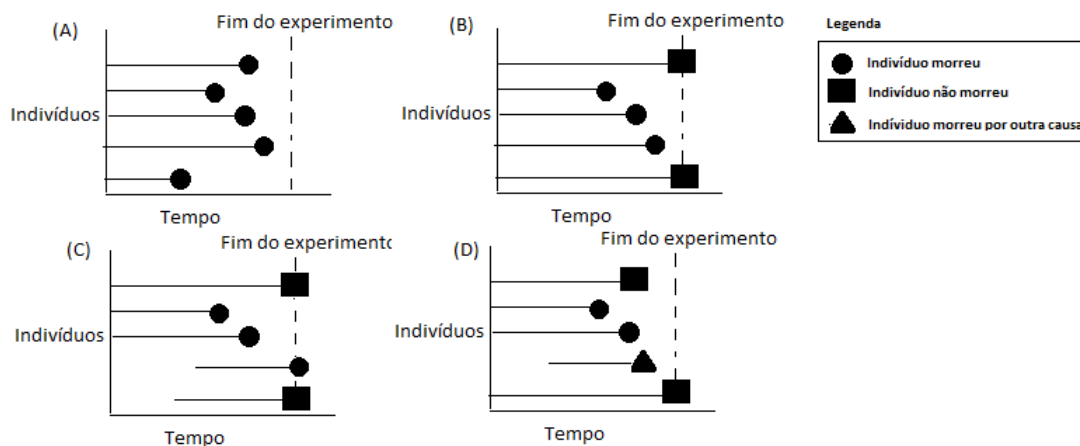


Figura 1 – Censuras. Círculo representa que o indivíduo morreu. Quadrado representa que o indivíduo permaneceu vivo. Triângulo representa morte por outros motivos não relacionados ao experimento. Fonte: (COLOSIMO; GIOLO, 2006).

ocorrência está à direita do tempo registrado. Existem também a censura à esquerda, que acontece quando o evento de interesse ocorreu antes do tempo registrado, e a intervalar quando se sabe que o evento ocorreu dentro de um intervalo de tempo qualquer, mas não sendo possível especificar quando exatamente.

Os tempos de sobrevivência podem ser limitados por um tempo inicial e um final, de modo que o experimento tem o início definido e terminará em um futuro próximo. O tempos de sobrevivências apresentados pelos indivíduos durante o decorrer do experimento podem sofrer variações aleatórias e, dessa maneira, são caracterizados como variáveis aleatórias. Assim como qualquer outra variável aleatória, os tempos de vida podem ou não seguir uma distribuição de probabilidade conhecida. Em caso positivo, utiliza-se métodos paramétricos para estimar os parâmetros de interesse, e, em caso contrário, métodos não-paramétricos são utilizados.

Um exemplo clássico de análise de sobrevivência é observado em experimentos médicos (CHEUNG; LEE; WONG, 2013) nos quais pesquisadores testam a eficiência de novos medicamentos em indivíduos com doenças terminais. Esses indivíduos são observados durante um determinado intervalo de tempo em que são registrados, quando possível, caso não ocorra censura, todos os tempos de vida. Com os tempos de vida devidamente registrados, é possível verificar se os indivíduos que tomaram um medicamento A tiveram uma maior taxa de sobrevivência do que os indivíduos que tomaram o medicamento B, por exemplo.

Assim como qualquer variável aleatória, as distribuições dos tempos de sobrevivência são caracterizadas por três funções: função densidade de probabilidade, função de sobrevivência e função de risco.

2.2 Função Densidade de Probabilidade $f(t)$

A distribuição de uma variável aleatória contínua é caracterizada através da sua função de densidade de probabilidade. A probabilidade dessa variável assumir um valor em um dado intervalo é dada pela integral da sua função $f(t)$ sobre esse intervalo. A função densidade é definida da seguinte maneira:

$$f(t) = \frac{\lim_{\Delta t \rightarrow 0^+} P[t \leq T < t + \Delta t]}{\Delta t}. \quad (2.1)$$

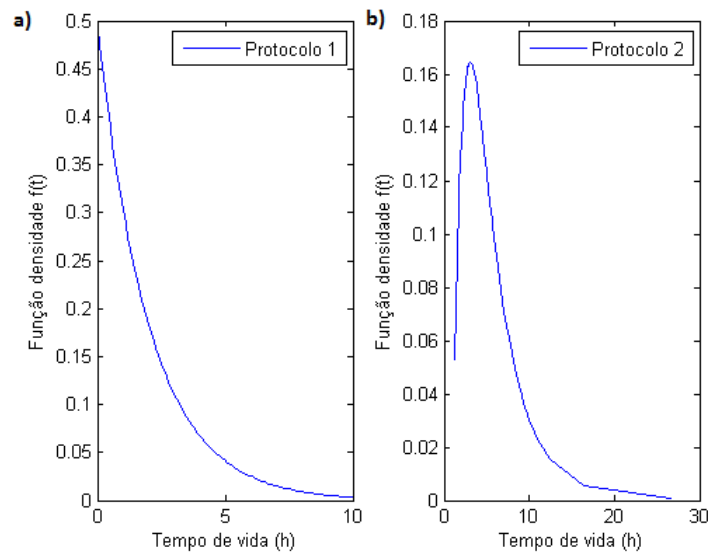


Figura 2 – Exemplos de duas funções densidade.

Para uma função $f(t)$ ser considerada uma função densidade de probabilidade de uma variável aleatória absolutamente contínua, ela deve satisfazer as seguintes condições:

1. A função $f(t)$ é não-negativa, ou seja, $f(t) \geq 0 \forall t \in \mathfrak{R}$. Em especial, se t é uma variável não-negativa:

$$\begin{cases} f(t) \geq 0 & \text{para todo } t \geq 0 \\ f(t) = 0 & \text{para } t < 0 \end{cases}$$

2. A área entre a função densidade e o eixo t é igual a 1, ou seja, se t é uma variável aleatória não-negativa, temos:

$$\int_{-\infty}^{\infty} f(t) dt = 1$$

Na Figura 2 são mostradas duas funções densidade que podem representar, por exemplo, duas estratégias de economia de energia para as redes de sensores sem fio. Observe

que o protocolo 1 (Figura 2a) apresenta uma elevada taxa de mortes no início, mas com o passar do tempo, essa taxa decai. Por outro lado, o protocolo 2 (Figura 2b) começa com uma taxa baixa, atinge seu ápice aproximadamente no instante 5 e em seguida decai.

2.3 Função de Sobrevivência $S(t)$

Seja T uma variável aleatória que representa o tempo de um indivíduo manifestar algum evento de interesse, a função de sobrevivência $S(t)$ é definida como a probabilidade da manifestação ocorrer após o instante t . No domínio das redes de sensores sem fio, essa função representa a probabilidade de um certo nó ainda está em estado funcional após t unidades de tempo. Em termos probabilísticos, ela é escrita como:

$$S(t) = P(T > t) = 1 - P[T \leq t], \quad \forall t \geq 0. \quad (2.2)$$




Figura 3 – Diferentes funções de sobrevivência.

A Função de Sobrevivência possui as seguintes propriedades:

1. $S(0) = 1$ i.e. todos os indivíduos estão vivos no começo do experimento;
2. $S(t)$ é contínua à direita;
3. $\lim_{t \rightarrow \infty} S(t) = 0$ i.e. eventualmente todos os indivíduos morrem;
4. $S(t_a) \geq S(t_b) \Leftrightarrow t_a \leq t_b$ i.e. $S(t)$ decresce monotonicamente.

Para variáveis aleatórias absolutamente contínuas, que são as mesmas utilizadas neste trabalho, a seguinte relação entre a função de sobrevivência e a função densidade é válida:

$$f(t) = \frac{d}{dt}[1 - S(t)] = -S'(t), \forall t \in \mathfrak{R}.$$

Na Figura 3 é mostrada a forma típica de duas funções de sobrevivência. O eixo horizontal representa o tempo de experimento e o eixo vertical representa a probabilidade de um indivíduo ainda está vivo nesse tempo. Esses gráficos podem representar, por exemplo, as taxas de sobrevivência dos nós de uma RSSF utilizando dois protocolos de roteamento distintos. Nesse caso, o gráfico representando a sobrevivência dos nós que foram programados com o Protocolo 1, por volta de 50 horas, 50% dos nós ainda estavam vivos. Observando esse mesmo percentil do Protocolo 2, o instante de tempo em que 50% dos nós estavam vivos foi observado por volta de 40 horas. Desse modo, pode-se observar que a taxa de sobrevivência apresentada pelo gráfico do Protocolo 1 é maior do que a apresentada pelo Protocolo 2.

2.4 Função de Risco Instantânea $h(t)$

A função de risco instantânea, ou taxa de falha instantânea, faz uma relação direta da quantidade de indivíduos que manifestaram o evento de interesse sobre a quantidade daqueles que ainda não manifestaram. Assim sendo, a função de risco descreve como a variação da taxa de falha instantânea varia ao longo do tempo. Ela é definida da seguinte maneira:

$$h(t) = \frac{\lim_{\Delta \rightarrow 0^+} P(T \leq t + \delta_t | T > t)}{\Delta t}. \quad (2.3)$$

É possível obter a função de risco instantânea $h(t)$ a partir da divisão entre a função densidade $f(t)$ e a função de sobrevivência $S(t)$, como mostrado na Equação (2.4)

$$h(t) = \frac{f(t)}{S(t)}. \quad (2.4)$$

Na Figura 4 são mostradas três funções de risco que podem representar três protocolos de roteamento, por exemplo. O protocolo 1 apresenta uma taxa de erro instantânea constante. Por outro lado, o protocolo 2 mostra um aumento na taxa de erro instantânea, o que quer dizer que a quantidade de indivíduos que estão manifestando o evento de interesse está aumentando ao longo do tempo. Por último, o protocolo 3 mostra que essa quantidade vai diminuindo com o decorrer do experimento.

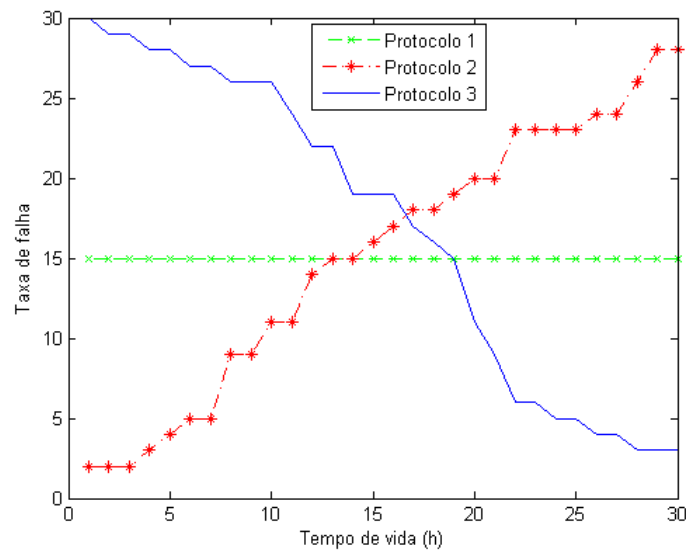


Figura 4 – Diferentes funções de risco instantâneas.

2.5 Modelos de Sobrevivência Paramétricos

A variável aleatória contínua que representa o tempo no qual um indivíduo participante de um experimento de sobrevivência leva para manifestar o evento de interesse segue ou não uma distribuição de probabilidade conhecida. Quando segue, é possível utilizar as funções de sobrevivência, função densidade e função de risco já especificadas para cada distribuição. De acordo com Colosismo e Giolo (2006), as distribuições apresentadas a seguir têm se mostrado bastantes adequadas para modelar tempo de vida de produtos industriais e na área médica.

2.5.1 Distribuição Exponencial

A distribuição exponencial é um dos modelos mais simples de se representar tempo de falha e é caracterizada por possuir a função de risco constante. Possui somente um parâmetro λ que representa a taxa de ocorrência de eventos independentes. Valores altos de λ indicam alto risco e baixa sobrevivência e valores baixos indicam baixo risco e alta sobrevivência.

Quando o tempo de ocorrência T de um evento de interesse segue essa distribuição, sua função densidade de probabilidade $f(t)$ é dada por:

$$f(t) = \lambda e^{-\lambda t}, \quad t \geq 0, \lambda > 0.$$

Já a sua função de sobrevivência $S(t)$ é dada por:

$$S(t) = e^{-\lambda t} \quad \text{para } t \geq 0.$$

E como dito anteriormente, a distribuição exponencial possui função de risco $h(t)$ constante, portanto:

$$h(t) = \lambda \quad t \geq 0.$$

2.5.2 Distribuição de Weibull

Quando o tempo de ocorrência T de um evento de interesse segue a distribuição de Weibull, sua função densidade de probabilidade $f(t)$ é dada por:

$$f(t) = \lambda\gamma(\lambda t)^{\gamma-1}e^{-(\lambda t)^\gamma}, \quad t \geq 0, \gamma, \lambda > 0.$$

Já sua função de sobrevivência $S(t)$ é dada por:

$$S(t) = e^{-(\lambda t)^\gamma}, \quad \forall t \geq 0.$$

Sua função de risco $h(t)$ é dada por:

$$h(t) = \lambda\gamma(\lambda t)^{\gamma-1}, \quad \forall t \geq 0.$$

A distribuição de Weibull é uma generalização da distribuição Exponencial, ou seja, a Exponencial é um caso particular da Weibull, mais precisamente quando $\gamma = 1$. Entretanto, ela não assume que a função de risco é constante, tornando assim aplicável para uma variedade de situações, seja função constante, decrescente ou crescente. Possui dois parâmetros γ , que é um parâmetro de forma, e λ , que é um parâmetro de escala.

2.5.3 Distribuição Log-normal

A distribuição log-normal é muito utilizada para caracterizar tempo de vida de produtos e indivíduos, incluindo fadiga de metal e diodos (COLOSIMO; GIOLO, 2006). Sua aplicação consiste em situações onde a taxa de falha inicialmente é crescente, atinge o seu máximo e então decresce. Se X é uma variável aleatória contínua com distribuição normal, então $Y = \exp(X)$ tem a distribuição log-normal. Os parâmetros dessa distribuição, μ e σ , não são a média nem o desvio padrão da distribuição log-normal e sim da distribuição normal.

Quando o tempo de ocorrência T de um evento de interesse segue a distribuição Log-normal, sua função densidade $f(t)$ de probabilidade é dada por:

$$f(t) = \frac{1}{t\sigma\sqrt{2\pi}} \exp\left[-\frac{1}{2\sigma^2}(\ln(t) - \mu)^2\right] \quad t > 0.$$

Já a sua função de sobrevivência $S(t)$ é dada por:

$$S(t) = \Phi\left(\frac{-\ln(t)+\mu}{\sigma}\right).$$

em que Φ representa a função de distribuição acumulada da normal padrão, ou seja:

$$\Phi(y) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^y e^{-\frac{u^2}{2}} du, \quad \forall y \in \mathbb{R}.$$

Sua função de risco $h(t)$ é dada por:

$$h(t) = \frac{1/t\sigma\sqrt{2\pi}\exp[-(\ln(at))^2/2\sigma^2]}{1 - \Phi(\ln(at)/\sigma)}.$$

2.6 Método de Máxima Verossimilhança

O método de máxima verossimilhança consiste em determinar, dentro de uma classe de distribuições, a mais verossímil dado a amostra observada. Por exemplo, se a distribuição dos tempos segue a de Weibull, para cada combinação dos parâmetros dessa, tem-se diferentes distribuições. Desse modo, esse estimador escolhe a melhor combinação que melhor explique a amostra observada.

A principal vantagem do método de máxima verossimilhança é possuir a capacidade de trabalhar com dados censurados no processo de estimação, não importando se os dados possuem censura do tipo I,II ou III. A estimação do parâmetro θ , em que θ representa os parâmetros da distribuição teórica, é dada por:

$$L(\theta) = \prod_{i=1}^r f(t_i; \theta) \prod_{i=r+1}^n S(t_i; \theta) \quad (2.5)$$

em que, supondo um conjunto de n observações $(1, 2, 3, \dots, r, r+1, r+2, \dots, n)$, as primeiras r observações representam valores não censurados e o restante representa observações censuradas.

2.7 Estimador de Kaplan-Meier

Quando não se conhece *a priori* uma distribuição de probabilidade que descreva os tempos observados de um determinado evento de interesse, pode-se utilizar estimadores não-paramétricos para estimar a função sobrevivência. O estimador que será utilizado neste trabalho é o de Kaplan-Meier, que, de acordo com Colosismo e Giolo (2006), é sem dúvida, o mais utilizado em estudos clínicos e vem cada vez mais ganhando espaço em estudos de confiabilidade.

O estimador de Kaplan-Meier é definido como:

$$\hat{S}(t) = \prod_{j:t_j < t} \left(1 - \frac{d_j}{n_j}\right) \quad (2.6)$$

em que os tempos de falhas t_1, t_2, \dots, t_k representam os tempos de falhas ordenados, d_j é o número de falhas ocorridas dentro do intervalo j e n_j é o número de indivíduos que não falharam até o instante anterior a t_j . Quando não houver censura, o estimador (2.6) se restringe à função de sobrevivência empírica, que é um estimador uniformemente consistente.

2.8 Áreas e exemplos de aplicação

A Análise de Sobrevivência tem sido utilizada pela comunidade científica de diferentes áreas do conhecimento. Chung, Schmidt e Witte (1991) apresentaram um estudo sobre a reincidência de crimes cometidos por prisioneiros recém libertados. Huang e Yu (2000) modelaram o quanto presentes trocados entre namorados ajudam a prolongar relacionamentos entre adolescentes. Woodall, Grambsch e Thomas (2005) modelaram a taxa de mortalidade de árvores em uma floresta de Minnesota nos Estados Unidos. Terawaki, Katsumi e Ducrocq (2006) modelaram o período onde vacas em Hokkaido no Japão permanecem produtoras de leite. Gondos et al. (2008) estudaram as taxas de sobrevivências de pacientes com câncer na Europa entre o período de 2000 até 2004. Masten e Foss (2010) modelaram a taxa de acidentes de trânsito entre motoristas adolescentes que possuem a carteira de motorista temporária em um estado dos Estados Unidos.

No domínio das Redes de Sensores sem Fio e nas Engenharias em geral, a Análise de Sobrevivência é comumente referenciada como Análise de Confiabilidade. Esse tipo de modelagem tem sido aplicado em diversos trabalhos, alguns dos quais descritos nas próximas subseções.

2.8.1 Trabalhos baseados em conectividade

A conectividade de uma RSSF é uma métrica importante de confiabilidade. De fato, para que uma rede seja considerada confiável é necessário que haja um caminho por onde as informações possam fluir, do nó de sensoriamento até o nó sorvedouro.

MurthyG e D'Souza (2012) modelaram a confiabilidade de rotas redundantes em redes de sensores com nós disjuntos com um ou mais caminhos disponíveis. Para eles, as rotas que possuem menos nós são consideradas mais confiáveis. Kim, Ghosh e Trivedi (2010) utilizaram cadeia de Markov e árvore de falha para modelar a confiabilidade em uma rede de sensores clusterizada. Doohan, Mishra e Tokekar (2011) afirmam que a confiabilidade de conexão depende de parâmetros ambientais como barulho, temperatura e pressão. Desse

modo, os autores propuseram uma função de sobrevivência que leva em consideração todos esses parâmetros. Wang et al. (2012) investigaram como diferentes topologias de rede de sensores influenciam na confiabilidade de conexão. Lee, Krishnamachari e Kuo (2008) modelaram a confiabilidade de conexão em uma rede de sensores extensa e que utiliza comunicação multi-salto.

2.8.2 Trabalhos baseados em energia

A energia armazenada em uma bateria de um nó é o que especifica o seu tempo de vida. Assim sendo, trabalhos que estão nessa categoria definem confiabilidade como a probabilidade da bateria não esteja completamente esgotada no intervalo $[0, t]$. Babulal e Tewari (2011) utilizaram a energia residual de um nó para especificar a confiabilidade de um link que conecta diversos membros. Wang et al. (2012) consideram que um nó é confiável se a sua bateria também for. Nesse contexto, o processo de descarregamento é modelado. Wang et al. (2013) estudaram como o descarregamento das baterias influencia no desempenho de protocolos da camada MAC.

2.8.3 Trabalhos baseados na vida útil de componentes

Os nós de uma rede de sensores são constituídos de componentes e esses influenciam diretamente no bom funcionamento de cada um dos nós. Se algum componente, por exemplo o rádio, não funcionar adequadamente, a confiabilidade da rede poderá ser prejudicada. Vasar et al. (2009b) utilizaram cadeia de Markov para modelar a confiabilidade dos componentes que constituem um nó. Já em (VASAR et al., 2009a), que é um trabalho dos mesmos autores, foi modelada a confiabilidade dos componentes, mas aplicado em uma fazenda de moinhos de vento.

2.8.4 Trabalhos baseados segurança

Na área de segurança Chen e Wang (2012) analisaram a confiabilidade de uma rede de sensores homogênea executando um protocolo de atestação de código.

2.8.5 Trabalhos baseados no tempo de vida

O tempo de vida dos nós está diretamente relacionado com a confiabilidade da rede. De fato, enquanto os nós permanecerem vivos a rede também permanecerá. Le et al. (2010) modelaram o tempo de vida dos nós da rede utilizando a distribuição exponencial em diferentes formas de organização dos nós. Até o presente momento, esse é o trabalho encontrado na literatura que se apresenta mais correlato à proposta deste trabalho. Entretanto, como será mostrado no Capítulo 4, a distribuição exponencial não apresenta estimativas precisas quando comparada a outros modelos paramétricos. Além

disso, o modelo proposto de cálculo da probabilidade sugere que a rede seja considerada viva enquanto existir pelo menos um nó vivo capaz de fazer a comunicação entre dois pontos distintos da rede (e.g. entre um nó sensor e o sorvedouro). Contudo, em redes nas quais uma grande quantidade de nós já estejam mortos, considerar a rede viva com somente alguns poucos pode levar a um monitoramento inadequado.

2.9 Resumo do capítulo

Esse capítulo apresentou definições iniciais de Análise de Sobrevivência. Foi definido o que vem ser esse tipo de análise, juntamente com o conceito de dado censurado. Foram apresentadas as principais funções de sobrevivência $(S(t), f(t), h(t))$ e três distribuições probabilísticas frequentemente utilizadas na análise de sobrevivência e que serão utilizadas neste trabalho. Foram apresentados o método não-paramétrico de Kaplan-Meier e o método de Máxima Verossimilhança. Por fim, foram expostos exemplos de trabalhos de variadas áreas do conhecimento que utilizaram Análise de Sobrevivência (ou Confiabilidade).

3 Material e Métodos

Neste capítulo é apresentado o delineamento utilizado para coleta e análise dos dados fundamentais para a aplicação da Análise de Sobrevivência no domínio das Redes de Sensores sem Fio. Ao final deste capítulo será possível, utilizando um modelo paramétrico, estimar: (i) o tempo de vida aproximado da rede; (ii) em qual intervalo de tempo aproximado acontecerão o maior número de mortes de nós e (iii) avaliar como será a taxa de falha instantânea desses nós ao longo do tempo. Esse delineamento abre caminho para esse tipo de análise no domínio em questão, tendo em vista que a Análise de Sobrevivência foi e é aplicada com sucesso, como visto no Capítulo 2, em diversas áreas do conhecimento.

3.1 Evento de interesse

Ao se trabalhar com Análise de Sobrevivência, é preciso identificar qual será o evento de interesse que se pretende modelar. Esse evento pode ser o tempo de ocorrência de uma determinada doença, morte de um indivíduo, falha de um componente de um sistema embarcado, entre outros, dependendo do domínio de estudo. No domínio das redes de sensores sem fio, podemos considerar como sendo o evento de interesse o instante no qual a rede sai de operação ou simplesmente "morre".

Entretanto, a morte de uma rede depende inteiramente dos nós que a compõe e esses podem morrer de diversas formas, como por exemplo, falha de algum componente (antena, CPU ou sensor), esgotamento das baterias ou até mesmo acidentes causados por terceiros. Modelar a sobrevivência de uma rede sob todas as circunstâncias possíveis não é uma tarefa trivial, e visando reduzir a complexidade da análise, consideramos nesta dissertação como evento de interesse, o instante em que um nó pertencente a uma rede tem suas baterias completamente descarregadas, situação essa que é caracterizada como a sua morte. Assim sendo, nesta dissertação estamos interessados em inferir estatísticas de sobrevivência de uma rede de sensores sem fio modelando a sobrevivência de seus nós.

3.2 Tempo de vida dos nós

Para este trabalho, um nó é considerado "vivo" quando existir pelo menos um caminho de comunicação entre o ele e o sorvedouro, seja através de conexão direta (*one-hop*) ou indireta (*multi-hop*). O tempo de vida do i -ésimo nó é dado pela equação (3.1):

$$t_{no_i} = \max(t_i) - \min(t_i), \quad (3.1)$$

em que t_{no_i} representa o tempo de vida do i -ésimo nó, $\max(t_i)$ e $\min(t_i)$ representam respectivamente os tempos de chegada da última e primeira mensagens oriundas do i -ésimo nó destinadas ao sorvedouro. Observe que os registros intermediários (entre os primeiro e último registros) não são considerados no cálculo do tempo de vida.

3.3 Tempo de vida da rede

Conforme mostrado no Capítulo 1, definir tempo de vida em redes de sensores sem fio não é algo trivial, já que essa definição muda de aplicação para aplicação. Para esta dissertação, seguimos uma das definições apresentadas em [Dietrich e Dressler \(2009\)](#), mais precisamente a que determina que o valor que representa a proporção de nós vivos é o fator determinante para especificar se uma rede é considerada viva ou não. Por questões de simplicidade, é mais comum considerar a rede morta quando o primeiro nó morre ([DIETRICH; DRESSLER, 2009](#)), entretanto, ela não é adequada a este estudo de sobrevivência, pois com somente essa informação não é possível realizar estimativa do tempo de vida da rede, uma vez que a morte de um único nó não representa que toda a rede venha a morrer. Por outro lado, esperar que todos os nós venham a morrer, como em [Tian et al. \(2000\)](#), não é uma métrica apropriada para definir tempo de vida, já que uma rede com uma boa quantidade de nós mortos e somente alguns vivo torna o monitoramento incompleto. Essa definição se torna ainda mais inadequada quando temos aplicações onde a vida humana está em risco, como por exemplo, uma aplicação de monitoramento de estruturas ([ROCHA et al., 2012](#)). Assim sendo, excluindo os casos extremos e avaliando diferentes percentis, consideramos como tempo de vida para este trabalho o tempo cujo 10, 51 ou 90% dos nós estão sem conectividade com o sorvedouro.

3.3.1 Cálculo do tempo de vida da rede

A função de sobrevivência $S(t)$ (ou função de confiabilidade) fornece a probabilidade de um nó está vivo após o instante t . Seguindo a definição de tempo de vida de [Cerpa et al. \(2004\)](#), cuja rede é considerada viva baseando-se na porcentagem de nós conectados ao(s) sorvedouro(s), pode-se estimar o tempo de vida da rede das seguintes maneiras:

1) se os tempos de vida dos nós seguem a distribuição Exponencial (λ):

$$t_{vida}(k) = -\ln(k)\lambda \quad (3.2)$$

2) se os tempos de vida dos nós seguem a distribuição de Weibull(λ, γ):

$$t_{vida}(k) = -\ln(k)^{\frac{1}{\gamma}}\lambda \quad (3.3)$$

3) se os tempos de vida dos nós seguem a distribuição Log-Normal(μ, σ):

$$t_{vida}(k) = e^{(\mu - \Phi^{-1}(k)\sigma)}, \quad (3.4)$$

em que k representa o percentil mínimo de nós mortos que, a partir do qual, a rede como um todo passar a ser considerada como morta. Vale ressaltar que o valor de k é definido de acordo com os requisitos da aplicação.

A função densidade de probabilidade $f(t)$, quando aplicada para descrever a variável aleatória contínua tempo de vida, permite avaliar a probabilidade de morte da rede dentro de um determinado intervalo de tempo específico. Além disso, ao observar o gráfico dessa função estimada, pode-se acompanhar a probabilidade de falha, para diferentes intervalos, ao longo do tempo. Com isso, é possível programar manutenções preventivas, seja recarregando as baterias ou repondo os nós, com o objetivo de prolongar a vida da rede.

A função de risco $h(t)$ permite avaliar a taxa de mortes dos nós ao longo do tempo. Essa taxa pode ser crescente, indicando que a quantidade de nós mortos cresce com o passar do tempo, decrescente indicando que essa quantidade diminui ou constante.

3.4 Modelos paramétricos e não-paramétricos

É importante enfatizar que as estimativas de sobrevivência podem ser obtidas através de métodos paramétricos ou não-paramétricos. Naturalmente, é mais simples utilizar as funções de probabilidade já definidas para cada uma das distribuições do que estimá-las utilizando um método não-paramétrico. Uma vez encontrada uma distribuição de sobrevivência que melhor se ajuste aos tempos de vida dos nós, é possível determinar as três funções que a caracterizam ($S(t)$, $f(t)$ e $h(t)$) (ver Capítulo 2). Neste trabalho, propomos a utilização de três métodos probabilísticos paramétricos, a saber Exponencial, Weibull e Log-Normal. De acordo com [Colosimo e Giolo \(2006\)](#), essas distribuições têm-se mostrado bastante adequadas quando se modela "tempo de falha" em processos industriais.

3.5 Ambiente de experimentos

Utilizamos como base a planta baixa do segundo andar do Grupo de Redes de Computadores, Engenharia de Software e Sistemas (GREat), que pode ser vista na Figura 5. Objetivando cobrir a maior parte possível do pavimento, implantamos fisicamente uma rede de teste com 24 nós e um sorvedouro para testarmos a conectividade dos nós ao longo dos corredores e gabinetes.

Inicialmente, posicionamos o *sink* na extremidade superior da rede, representado pelo nó azul na Figura 5. Após o início da operação da rede, foi percebido que a parte superior dela, representada pelos nós verdes, conseguiram se comunicar diretamente (*one-hop*) ou indiretamente (*multi-hop*) com o sorvedouro. Por outro lado, a parte inferior, representada pelos círculos vermelhos, não o conseguiram. Para contornar essa falta de



Figura 5 – Rede implantada com servidor posicionado na extremidade.

conectividade, posicionamos o servidor na parte mais central do pavimento, mais precisamente dentro do gabinete 02. Com esse novo posicionamento do servidor, todos os nós conseguiram transmitir com sucesso seus dados até ele.

A partir da implantação da rede de teste, conseguimos definir uma topologia que é capaz de cobrir a maior parte do pavimento e ainda possibilita que todos os nós se comuniquem efetivamente com o servidor.

3.6 Material

Os experimentos foram realizados utilizando 25/26 nós MicaZ com sistema operacional Contiki (DUNKELS; GRONVALL; VOIGT, 2004). Como ferramenta de simulação, utilizamos o Cooja (OSTERLIND, 2006). O Cooja permite simulações de redes de sensores sem fio utilizando o padrão IEEE 802.15.4, cuja taxa máxima de transmissão é igual a 250 kbps e a potência máxima de saída não passa de 1 mW. O Cooja possui como vantagem o suporte a diversas plataformas compatíveis com o Sistema Operacional Contiki, dentre elas está o MicaZ, que foi utilizado nos nossos experimentos. Para desempenhar simulações, utilizamos a estrutura física do Centro Nacional de Processamento de Alto Desempenho - UFC (CENAPAD).

Cada nó foi programado para enviar 1 *byte* de informação a cada 15 segundos. Além disso, utilizamos a pilha de protocolos Rime (DUNKELS, 2007) para realizar a comunicação fim a fim e o protocolo CSMA para o controle de acesso ao meio. Para alimentar os nós, usamos duas pilhas alcalinas AA novas de marca Duracell. É importante ressaltar que, tanto no experimento com sensores reais como no simulado, com o objetivo de

diminuir a duração dos experimentos, não utilizamos nenhuma estratégia de desligamento dos rádios.

3.7 Delineamento - estratégia de estudo

O delineamento ilustra a estratégia de pesquisa adotada nesta dissertação e foi organizado conforme ilustrado na Figura 6. Cada passo do delineamento está explicado nas subsecções a seguir.

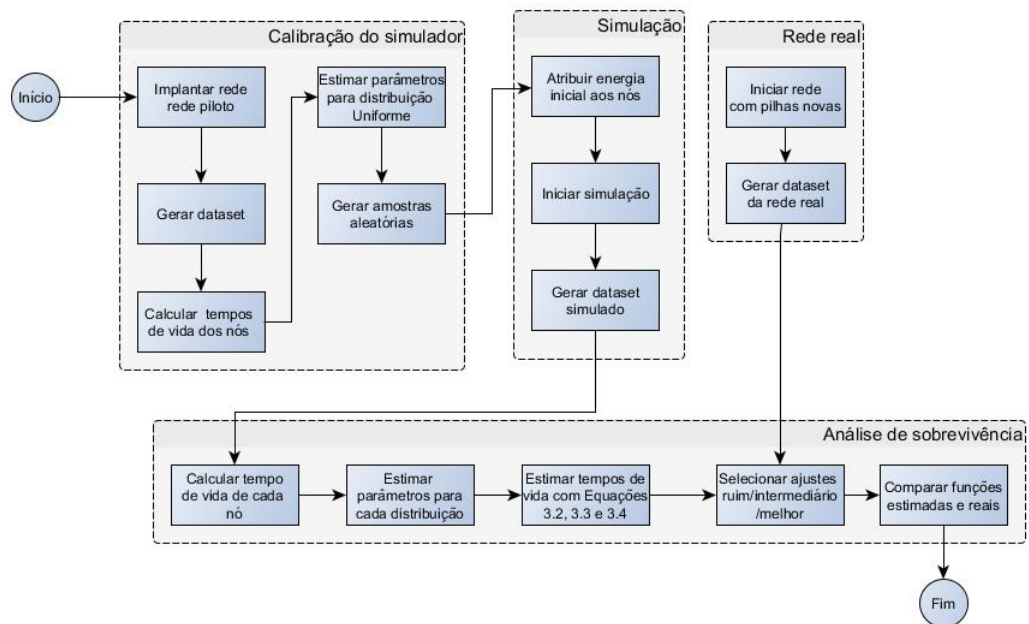


Figura 6 – Delineamento.

3.7.1 Calibração do simulador

Por ser um ambiente idealizado, é necessário que o simulador passe, primeiramente, por um processo de calibragem estatística. Esse processo consiste em utilizar variáveis aleatórias modeladas a partir de uma rede piloto e replicá-las no simulador com o objetivo fidelizá-lo conforme as mesmas condições dessa rede. Quanto mais variáveis forem replicadas no simulador mais realista a simulação ficará. Para esse trabalho, replicamos a variação de carga inicial de pilhas no simulador. A variação aleatória da energia inicial em pilhas foi observada em Park et al. (2005).

A rede piloto (Figura 7) consistiu de 6 nós e 1 sorvedouro, que foi posicionado no centro da rede. Os nós foram espalhados ao redor do sorvedouro de forma que as distâncias entre eles e o *sink* fossem iguais, garantindo que todos os nós possuíssem condições semelhantes em relação a comunicação direta com o *sink*. Todos os nós, com exceção do sorvedouro, que estava conectado ao computador através de um cabo USB,

utilizaram pilhas alcalinas AA novas da marca Duracell. A rede foi executada duas vezes e na segunda execução as pilhas da primeira execução foram substituídas por pilhas novas de mesmo modelo e marca. Os tempos de vida dos nós são apresentados na Tabela 1.




Figura 7 – Rede piloto utilizada para calibrar o simulador.

Tabela 1 – Tempos que indicam últimos registros de vida dos nós da rede piloto.

| Nó | Tempos 1 (h) | Tempos 2 (h) |
|----|--------------|--------------|
| 1 | 106,2 | 106,4 |
| 2 | 107,2 | 104,3 |
| 3 | 103,1 | 109,7 |
| 4 | 104,6 | 108,0 |
| 5 | 108,6 | 103,7 |
| 6 | 99,3 | 102,3 |

A carga energética inicial de uma pilha AA alcalina nova tem aproximadamente 9360 Joules [All About Batteries, 2011]. A plataforma MicaZ é alimentada por 2 pilhas, totalizando 18.720 Joules. Replicamos a rede piloto no simulador e atribuímos essa carga como energia inicial dos nós. Para modelar o descarregamento das baterias no simulador, foi utilizada a ferramenta Energest do Contiki. Ela fornece o tempo de operação de cada componente do dispositivo (transmissor, receptor e CPU). Sabendo o tempo de operação de cada um deles e observando no *datasheet* do MicaZ o consumo energético de cada um deles, podemos simular o descarregamento das pilhas. Ao final da simulação, que durou aproximadamente dois dias, foi observado que os nós obtiveram tempo médio de vida de aproximadamente 94 horas. Sabendo que os nós vivem aproximadamente esse tempo no simulador, aplicamos o seguinte cálculo para estimar a energia inicial, em Joules, das

pilhas do i -ésimo nó:

$$Carga_{inicial_i} = \frac{18720 * T_i}{94} \quad (3.5)$$

,cujo T_i representa o tempo de vida do i -ésimo nó da rede piloto.

Vale ressaltar que carga inicial varia aleatoriamente, caracterizando-a como uma variável aleatória. Assumindo que a carga inicial é uniformemente distribuída, obtêm-se que as cargas iniciais das pilhas Duracell Alcalina AA são geradas a partir da distribuição Uniforme contínua (min = 19794, max = 21847). Gerando amostras a partir dela e atribuindo cada valor a cada um dos nós no simulador, tentamos replicar as variações aleatórias da carga inicial das pilhas na ferramenta de simulação.

É importante enfatizar que a calibração é um processo inerente à aplicação em questão e depende de fatores como: tipo de bateria, plataforma de hardware, sistema operacional, pilha de protocolos, topologia da rede e o simulador utilizado. Possivelmente, se refizéssemos a calibração com outro tipo de pilha, outro tipo de plataforma de hardware ou outro simulador, a distribuição que modela a carga inicial seria diferente da encontrada.

3.7.2 Simulação

A partir da topologia mostrada na Figura 5, criamos um cenário de simulação onde replicamos o posicionamento dos nós e a partir dele simulamos a rede 30 vezes, gerando um *dataset* em cada simulação. Atribuímos valores aleatórios de energia inicial originados a partir da distribuição Uniforme contínua (min = 19794, max = 21847) (ver Seção 3.7.1). Assim como na rede piloto, utilizamos a ferramenta Energest do Contiki e simulamos o descarregamento das pilhas ao longo do tempo. Como modelo de transmissão de dados, foi utilizado o *Unit Distance Graph Medium: Distance Loss* com os seguintes parâmetros:

- Alcance de transmissão: 15 metros;
- Alcance de interferência: nenhum;
- Taxa de sucesso de transmissão: 100%;
- Taxa de sucesso de recepção: 100%.

3.7.3 Rede real

A seguir descrevemos as duas redes reais implantadas para a realização dos experimentos desta dissertação.

3.7.3.1 Cenário #1 - Rede com 1 sorvedouro

Após os testes preliminares de posicionamento dos nós e as 30 simulações, a rede foi implantada de forma definitiva, ver Figura 8. Para esse experimento, cada um dos nós foi energizado por duas pilhas alcalinas AA Duracell novas, garantindo que todos eles possuíssem aproximadamente as mesmas condições iniciais em termos de carga inicial. Vale ressaltar, ainda, que todos os nós tinham conhecimento *a priori* do endereço do sorvedouro e o algoritmo de roteamento se encarregava de encaminhar os pacotes até ele. Por fim, a rede foi deixada em operação até o momento em que os sorvedouros deixaram de receber pacotes oriundos dos nós coletores.



Figura 8 – Rede do cenário #1.

A Figura 9 apresenta a arquitetura da rede utilizada neste cenário. Assim como na rede piloto (3.7.1), todos os nós enviaram seus pacotes ao sorvedouro a cada 15 segundos utilizando o padrão IEEE 802.15.4. Esse, por sua vez, estava conectado através de um cabo USB a um computador que era responsável por detectar o recebimento de mensagens e salvá-las em um Sistema Gerenciador de Banco de Dados (SGBD).

3.7.3.2 Cenário #2 - Rede com 2 sorvedouros

Na rede anterior, quando o sorvedouro foi posicionado na "borda" superior da rede, alguns nós, aqueles que estavam na parte inferior da Figura 5, ficaram incomunicáveis. Para resolver esse problema, posicionamos o sorvedouro próximo à parte central da rede. Entretanto, uma outra solução que poderia ser feita em relação a falta de conectividade seria adicionar um novo sorvedouro na parte inferior, que ficaria responsável por receber dados desses nós que antes estavam incomunicáveis. Com esse propósito, apresentamos




Figura 9 – Arquitetura da rede do cenário #1.

uma segunda rede com dois sorvedouros na Figura 10. Nessa nova topologia, os nós representados pelos endereços 5, 18, 106, 7, 21, 14, 10, 108, 5, 109 e 105 enviaram seus dados ao sorvedouro 1 e os nós 16, 6, 17, 11, 3, 2, 107, 9, 4, 12, 13, 19 e 110 ao sorvedouro 0.

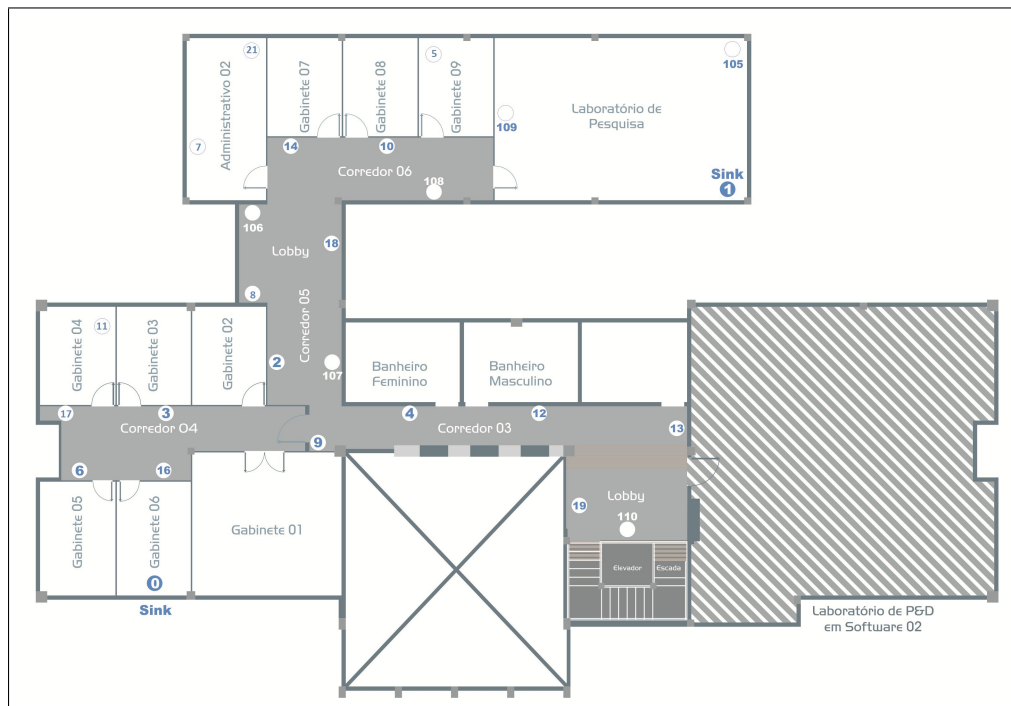


Figura 10 – Rede do cenário #2.

Vale ressaltar que os parâmetros de configuração das simulações da rede nesse novo

cenário foram idênticos aos da rede do primeiro cenário. A única diferença ficou por conta da alteração da topologia, que contou com dois sorvedouros. Já a arquitetura da rede real para esse novo cenário é mostrada na Figura 11. Nesse caso, os dois computadores os quais os sorvedouros estavam conectados, foram interligados por uma rede local. O servidor de banco de dados foi executado no computador correspondente ao sorvedouro 1 e o outro computador, ao detectar a chegada de pacotes, utilizava a rede local para inserir seus dados no banco. Por fim, assim como no primeiro caso, a rede foi deixada em operação até o momento em que os sorvedouros deixaram de receber pacotes.




Figura 11 – Arquitetura da rede do cenário #2.

3.7.4 Metodologia de análise de sobrevivência

Após todas as simulações, obtivemos 60 *datasets*, 30 para cada cenário, que contêm os registros de recebimentos de mensagens de cada um dos nós no sorvedouro. Como estamos interessados no tempo de vida dos nós, aplicamos a Equação 3.1 para calcular o tempo de vida de cada um deles em cada simulação. Em seguida, ajustamos os tempos de vida aos modelos Exponencial, Weibull e Log-Normal utilizando o método da máxima verossimilhança. Com os parâmetros estimados, utilizamos as Equações 3.2, 3.3 e 3.4 para estimar o tempo de vida da rede real segundo cada modelo.

Analisando o *dataset* da rede real e considerando o tempo de vida como descrito na Seção 3.3, conseguimos determinar, precisamente, qual foi o tempo de vida da rede. Considere, por exemplo, em uma rede com 24 nós, se a rede é considerada como morta quando somente 50% deles estão vivos ($k = 0.5$), o instante de tempo correspondente a morte do décimo segundo nó representa o seu tempo seu vida, ou seja, o instante no

qual a quantidade de nós vivos passa de 51 para 50%. Uma vez determinado o tempo de vida da rede real, podemos compará-la com cada estimativa realizada através dos dados gerados em simulação.

Ajustamos os tempos de vida dos nós observados nas simulações às distribuições Exponencial, Weibull e Log-Normal, com o objetivo de estimar as três funções de interesse ($S(t)$, $f(t)$ e $h(t)$). Cada modelo gerou 90 gráficos, ou seja, 30 funções de sobrevivência ($S(t)$), 30 funções densidade ($f(t)$) e 30 funções de risco $h(t)$, totalizando 270 gráficos por cenário. Para cada gráfico, comparamos-o ao seu respectivo gráfico gerado através de métodos não-paramétricos, utilizando o método de comparação gráfico (COLOSIMO; GIOLO, 2006), construídos a partir dos tempos observados da rede real. Utilizamos o método não-paramétrico de Kaplan-Meier (seção 2.7) para construirmos a função de sobrevivência e o estimador não-paramétrico *Kernel* para construirmos a função densidade. A função de risco não-paramétrica foi obtida através da divisão entre a função a função densidade e a função de sobrevivência. Por fim, comparamos cada um dos gráficos com seu correspondente não-paramétrico, objetivando identificar, para cada modelo, 3 tipos de ajustes: ruim, intermediário e bom, para em seguida discutirmos os gráficos selecionados.

3.8 Resumo do capítulo

Neste capítulo, apresentamos como a análise de sobrevivência pode ser aplicada no domínio das redes de sensores sem fio para estimar funções de sobrevivência de uma rede em simulador estatisticamente calibrado, antes de implantá-la fisicamente, analisando os tempos de vidas dos nós que a compõe. Para isso, propomos a utilização dos modelos exponencial, Weibull e log-normal, tendo em vista que esses apresentaram bons resultados em outras áreas do conhecimento, particularmente na modelagem do tempo de falhas em produtos industriais. Através da presente proposta, é possível determinar qual será o tempo de vida aproximado da rede, em qual intervalo de tempo aproximado acontecerão o maior número de mortes de nós e avaliar como será a taxa de falha instantânea desses nós ao longo do tempo. Apresentamos também os materiais e cenários utilizados para a realização dos experimentos desta dissertação. Implantamos fisicamente duas redes, uma com 1 e a outra com 2 sorvedouros as quais serviram para validar as estimativas feitas em simulação. Por fim, descrevemos os experimentos realizados e suas respectivas metodologias.

4 Resultados e Discussões

Neste capítulo apresentamos os resultados alcançados ao aplicarmos a metodologia descrita no Capítulo 3 para avaliarmos o quão os modelos exponencial, Weibull e log-normal conseguem modelar o tempo de vida dos nós e, conseqüentemente, o tempo de vida da rede. Os resultados são discutidos sobre 4 aspectos: (i) a precisão da estimativa do tempo de vida da rede obtida através das Equações 3.2, 3.3 e 3.4 (vide Capítulo 3); (ii) a comparação entre a função de sobrevivência estimada pelos modelos probabilísticos e a função de sobrevivência estimada pelo método não-paramétrico; (iii) a comparação entre as funções densidade paramétrica e não-paramétricas; e (iv) a comparação entre as funções de risco paramétrica e não-paramétrica.

4.1 Rede com 1 sorvedouro

Nesta Seção apresentaremos os resultados obtidos para os modelos exponencial, Weibull e log-normal quando utilizados para modelar o tempo de vida da rede com 1 sorvedouro apresentada no Capítulo 3 (ver Seção 3.7.3.1).

4.1.1 Modelo Exponencial

Primeiramente, avaliaremos a precisão das estimativas inferidas pelo modelo exponencial. Ao final das 30 simulações e, aplicando a Equação 3.2, obtivemos os resultados apresentados na Figura 12.

Na Figura 12 apresentamos 3 estimativas utilizando diferentes definições de tempo de vida da rede. Na primeira, mostrada na Figura 12a, a rede foi considerada como morta quando 10% dos seus nós morreram. Na segunda, mostrada na Figura 12b, a rede foi considerada como morta quando 51% dos seus nós morreram. E por fim, na Figura 12c, a rede foi considerada como morta quando 90% dos nós morreram. Além disso, cada Figura conta com 3 funções, uma constante que representa o tempo de vida observado na rede física, outra representando as estimativas obtidas pelo modelo exponencial e por fim os intervalos de predição.

Analisando a Figura 12, observa-se que, em nenhuma caso, o modelo exponencial conseguiu estimar corretamente o tempo de vida da rede real, apresentando piores resultados ao se considerar os percentis 10 e 90. No percentil 10, o erro foi mais de 50 horas e no percentil 90 o erro foi de aproximadamente 100 horas. As estimativas que mais se aproximaram do tempo observado na rede real foram as inferidas a partir do percentil 51. Nesse caso, o tempo de vida da rede real ficou próximo do intervalo de predição.

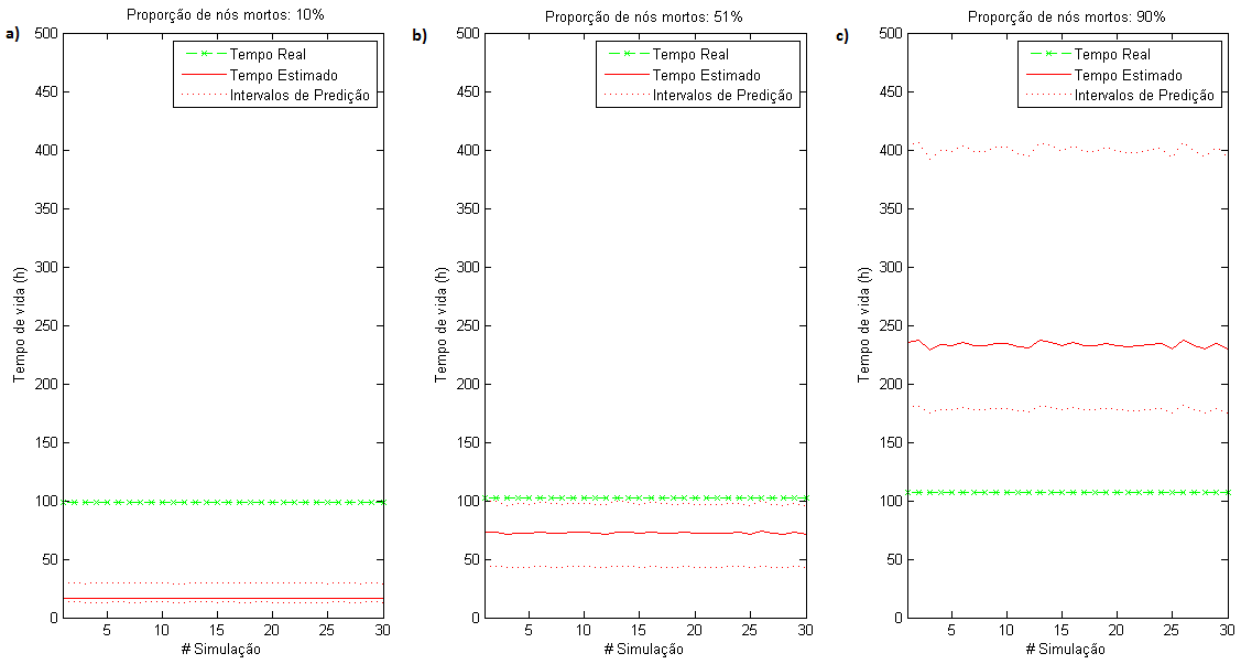


Figura 12 – Estimativas obtidas a partir do modelo exponencial para diferentes definições de tempo de vida (a. 10%, b. 51% e c. 90%).

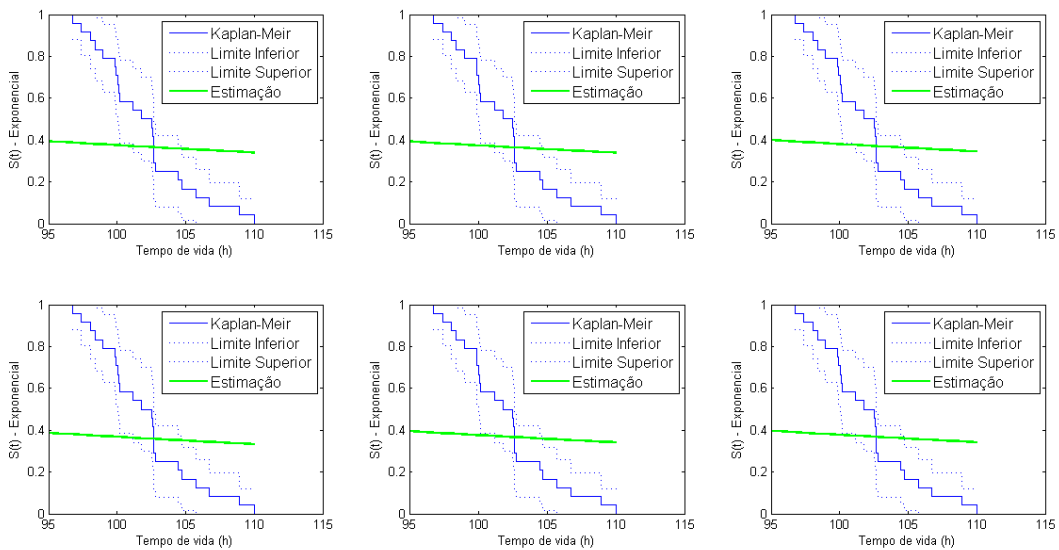


Figura 13 – Comparação entre a função estimada pelo modelo exponencial e pelo método não-paramétrico de Kaplan-Meier.

Analizamos os 30 *datasets* gerados a partir das simulações da rede com 1 sorvedouro, comparamos as estimativas da função de sobrevivência inferida através do modelo exponencial com a estimativa inferida pelo método não-paramétrico de Kaplan-Meier. Percebemos que, em todas elas, as funções não se ajustaram bem. Separamos 6 gráficos dos 30, que podem ser observados na Figura 13. Vale a pena observar que, nesses gráficos, o modelo exponencial estimou que, por volta de 110 horas, aproximadamente 30% dos nós

ainda estariam vivos, o que não foi observado na prática.

A partir dos resultados obtidos até agora para a distribuição exponencial, verificamos que esse modelo não conseguiu estimar/ajustar, de forma satisfatória, o tempo de vida da rede com 1 sorvedouro utilizada neste experimento. Assim sendo, não construiremos os gráficos das funções densidade e de risco.

4.1.2 Modelo Weibull

Avaliamos em seguida a precisão das estimativas obtidas pelo modelo Weibull. Ao final das 30 simulações e, aplicando a Equação 3.4, obtivemos os resultado apresentados na Figura 14.

Diferentemente das estimativas inferidas pelo modelo exponencial, o tempo de vida da rede física ficou a maior parte do tempo dentro do intervalo de predição inferido pelo modelo Weibull nos 3 percentis avaliados. Entretanto, como pode ser observado na Figura 14, a medida que se aumenta o percentil de nós mortos, aumenta também a precisão da estimativa. Isso sugere que o modelo Weibull é recomendado para aplicações que consideram a rede como morta quando a maioria dos nós estão mortos ($k \geq 0,51$).

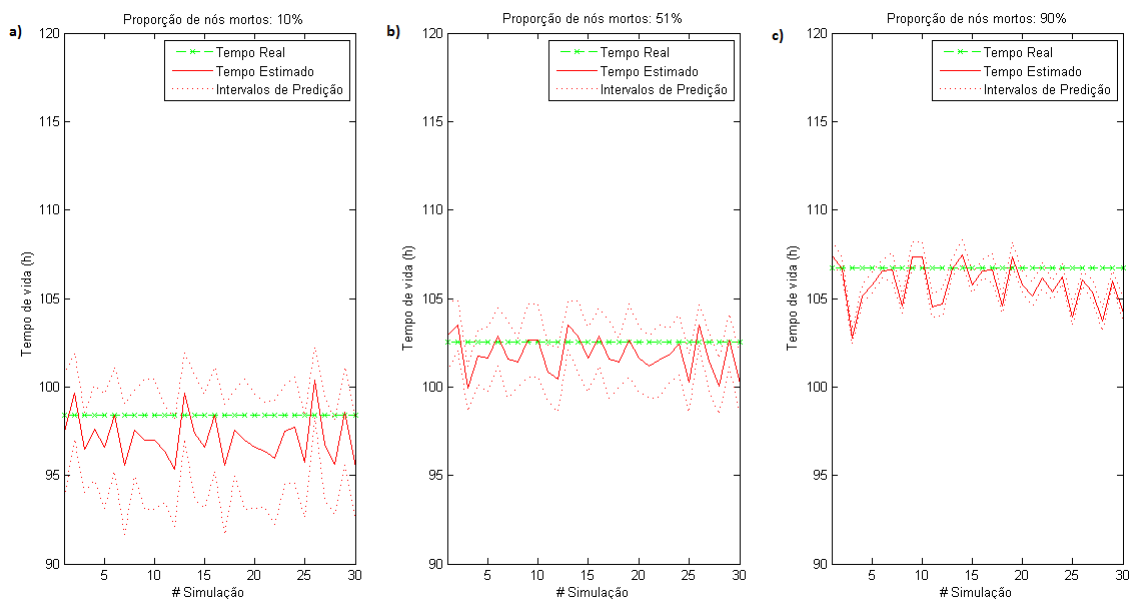


Figura 14 – Estimativas obtidas a partir do modelo Weibull para diferentes definições de tempo de vida (a. 10%, b. 51% e c. 90%).

A partir da análise dos 30 *datasets*, obtidos através das simulações, analisamos cada um deles e comparamos, através do método gráfico, a curva de sobrevivência estimada pelo modelo Weibull com a curva obtida através do método não-paramétrico de Kaplan-Meier, com o objetivo de avaliar três tipos de ajustes: ruim, intermediário e bom. Na Figura 15 são apresentados 3 gráficos para cada ajuste. O gráfico 15a apresenta a análise de um

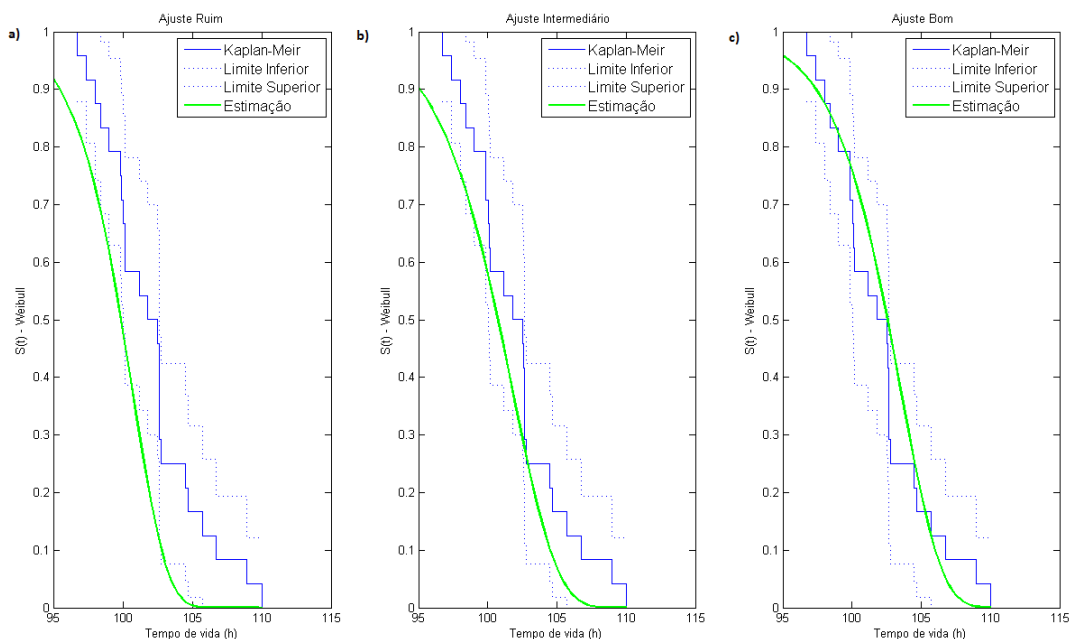


Figura 15 – Estimativas das funções de sobrevivência obtidas a partir do modelo Weibull para a rede com 1 servidor (ajustes a. ruim, b. intermediário e c. bom).

dataset que teve ajuste ruim. Nesse caso, é possível observar que, a estimativa inferida pelo modelo Weibull, não está contida no intervalo de confiança não-paramétrico. De acordo com a estimaco, o ltimo n morreria por volta de 105 horas, e na rede fsica esse tempo foi aproximadamente 110 horas. Ainda assim, mesmo com esse tipo de *dataset*, é possvel saber *a priori* uma aproximao da sobrevivncia da rede com uma taxa de erro aceitvel, ou seja, no mximo 5 horas. O grfico 15b apresenta um *dataset* onde foi observado um ajuste intermedirio, pois a estimativa inferida pelo modelo Weibull entra no intervalo de confiana por volta de 100 horas, ou ainda quando aproximadamente 70% dos ns esto vivos.  possvel observar que, nesse caso, o erro de estimativa diminuiu quando comparado ao caso anterior. Por fim o grfico 15c mostra a curva de sobrevivncia inferida a partir de um *dataset* em que os tempos de vida dos ns obtidos foram bastantes prximos ao da rede fsica. Nesse caso, é possvel visualizar que a curva estimada pelo modelo Weibull consegue se ajustar melhor a curva inferida pelo modelo no-paramtrico at a morte do ltimo n.

Analisamos os *datasets* avaliando o ajuste da funo densidade estimada pelo modelo Weibull com a funo densidade obtida atravs de um mtodo no-paramtrico, nesse caso utilizamos o estimador *kernel*. Na Figura 16 so apresentados 3 grficos com diferentes tipos de ajuste: ruim, intermedirio e bom. O grfico 16a mostra um caso de ajuste ruim. Nesse caso, a funo estimada no se ajusta bem quando comparada a estimada pelo mtodo no-paramtrico. Entretanto, os picos das funo densidade das duas curvas so relativamente prximos, por volta de 100 horas, significando que, mesmo no pior caso, é possvel determinar com erro de no mximo 3 horas o instante

onde acontecerão o maior número de mortes dos nós. No caso apresentado no gráfico 16b, essa diferença diminui ainda mais. Por fim, no melhor caso apresentado no gráfico 16c, é possível observar que a função densidade estimada pelo método paramétrico ficou bem ajustado ao estimado pelo método não-paramétrico. Nesse caso, os picos das funções ficaram bastantes próximos.

Por fim, analisando os *datasets* em termos da função de risco, mostramos na Figura 17, as funções de risco estimadas pelo modelo Weibull sendo comparadas à função de risco obtida através do método não-paramétrico (*kernel*). No gráfico 17a apresentamos um caso onde o ajuste foi considerado por nós como ruim. Nesse caso, a taxa de falha estimada pelo modelo Weibull cresce mais devagar quando comparada ao método não-paramétrico. No gráfico 17b foi observado um melhor ajuste e é possível observar que a taxa de falha estimada pelo modelo Weibull se aproximou da estimativa inferida pelo método não-paramétrico. Por fim, no gráfico 17c foi observado um bom ajuste entre as funções de risco. Nesse caso, a taxa de falha estimada pelo modelo Weibull acompanhou bem a estimativa do método não-paramétrico.

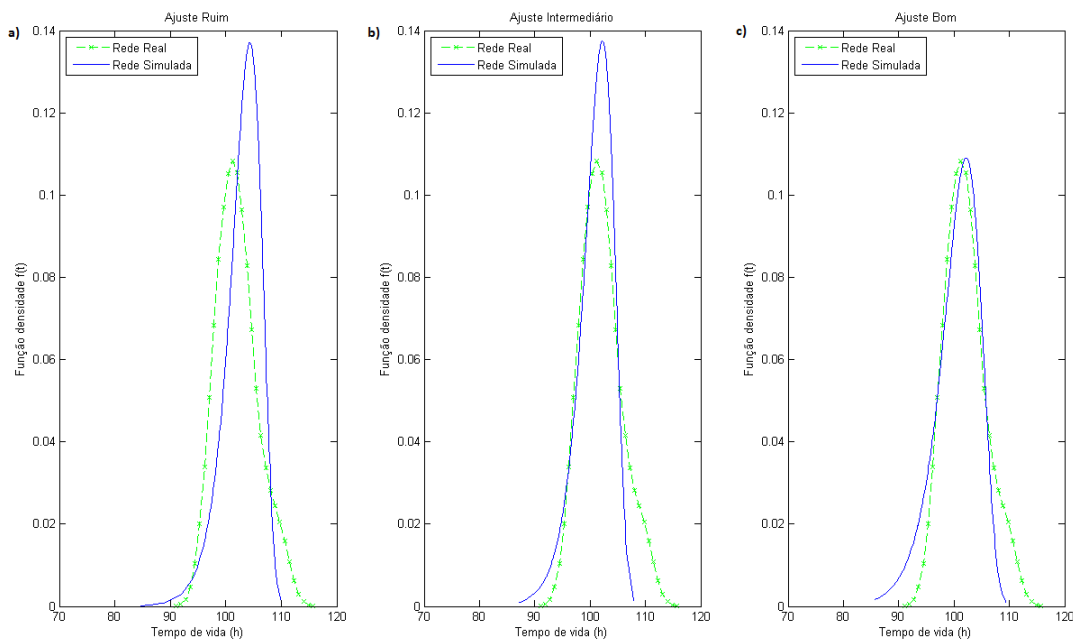


Figura 16 – Estimativas das funções densidade obtidas a partir do modelo Weibull para a rede com 1 sorvedouro (ajustes a. ruim, b. intermediário e c. bom).

4.1.3 Modelo log-normal

Por fim, avaliamos a precisão das estimativas inferidas pelo modelo log-normal. Ao final das 30 simulações e, aplicando a Equação 3.4, obtivemos os resultados apresentados na Figura 18.

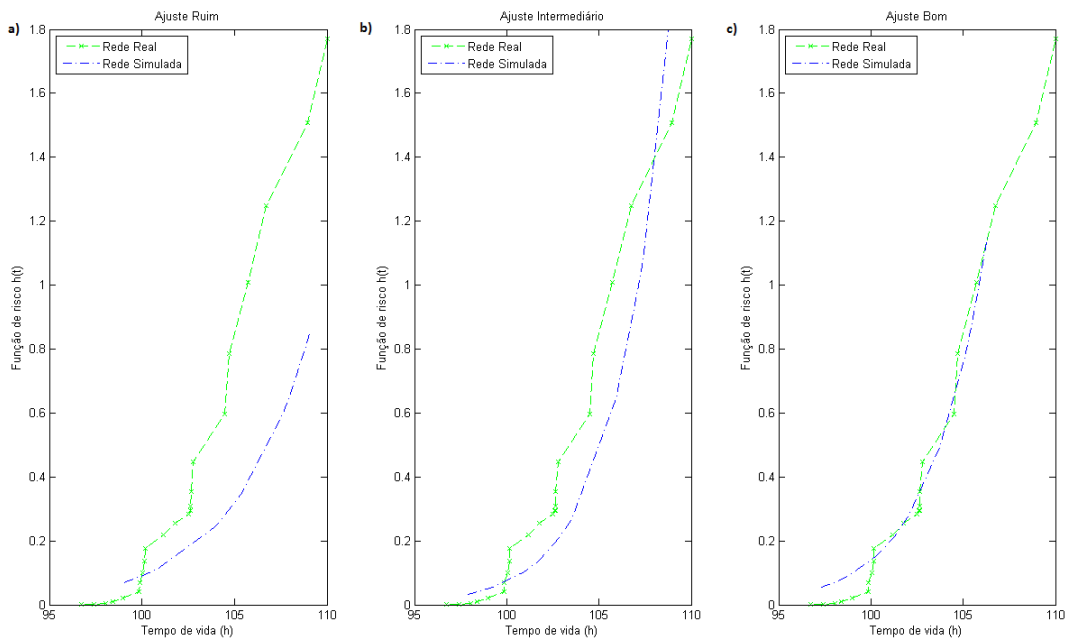


Figura 17 – Estimativas das funções de risco obtidas a partir do modelo Weibull para a rede com 1 sorvedouro (ajustes a. ruim, b. intermediário e c. bom).

Analisando a Figura 18, observa-se que o modelo log-normal, assim como o modelo Weibull, conseguiu estimar bem o tempo de vida da rede real nos 3 percentis avaliados. Entretanto, ao contrário do observado no modelo Weibull, a precisão diminui quando se aumenta o percentil de nós mortos, indicando que o modelo log-normal é recomendado para aplicações que consideram a rede como morta quando a minoria dos nós estão mortos ($k \leq 0,50$).




Figura 18 – Estimativas inferidas a partir do modelo log-normal para diferentes definições de tempo de vida (a. 10%, b. 51% e c. 90%).

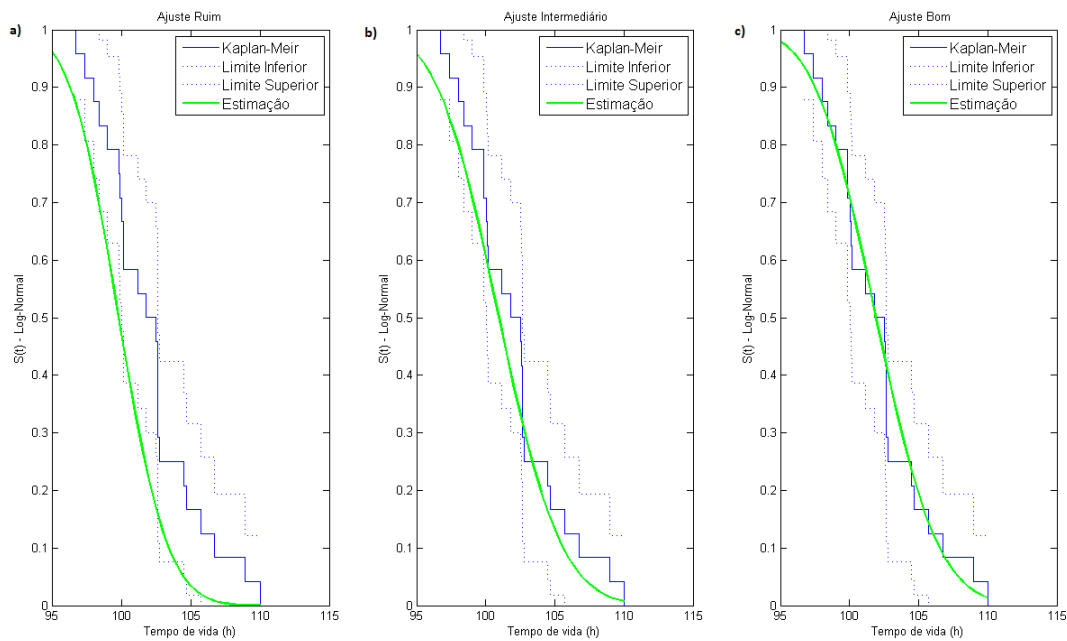


Figura 19 – Comparação entre as funções de sobrevivência estimadas pelo modelo log-normal e da rede real (ajustes a. ruim, b. intermediário e c. bom).

Assim como no modelo Weibull, analisamos os 30 *datasets* obtidos através das simulações e comparamos a curva de sobrevivência estimada pelo modelo log-normal com a curva obtida através do método não-paramétrico de Kaplan-Meier, com o objetivo de avaliar três tipos de ajustes: ruim, intermediário e bom. Na Figura 19 são mostrados os gráficos comparativos para cada tipo de ajuste. No gráfico 19a, é possível observar que, assim como no modelo Weibull, a estimativa da função de sobrevivência tangencia a borda inferior do intervalo de confiança estimado pelo método não-paramétrico. Entretanto, ainda sim é possível inferir estimativas da sobrevivência da rede com erro de no máximo 3 horas. No gráfico 19b, a função de sobrevivência estimada pelo modelo log-normal se ajusta melhor a função estimada pelo método não-paramétrico, entrando no intervalo de confiança por volta 99 horas, ou quando aproximadamente 15% dos nós estão mortos. Por fim, no gráfico 19c, é possível observar um melhor ajuste quando comparado aos casos anteriores. Além disso, o ajuste é ainda melhor do que o observado no melhor caso do modelo Weibull.

Na Figura 20 são mostradas as comparações das estimativas da função densidade, inferida pelo modelo log-normal, com a função densidade estimada pelo método não-paramétrico obtida através do estimador *kernel*. No gráfico 20a a função densidade estimado pelo modelo log-normal não se ajustou bem a estimada pelo método não-paramétrico. Entretanto, os picos das funções ficaram relativamente próximos, indicativo desse que, mesmo no pior caso, é possível se determinar com uma taxa de erro aceitável, utilizando o modelo log-normal, o instante onde ocorrerão o maior número de mortes dos nós. No

gráfico 20b o ajuste é bem melhor, diminuindo o erro da estimativa. Por fim, no gráfico 20c, o ajuste foi muito bom, a estimativa da função obtida pelo modelo log-normal ficou bem ajustada se comparamos com aquela estimada pelo método não-paramétrico.

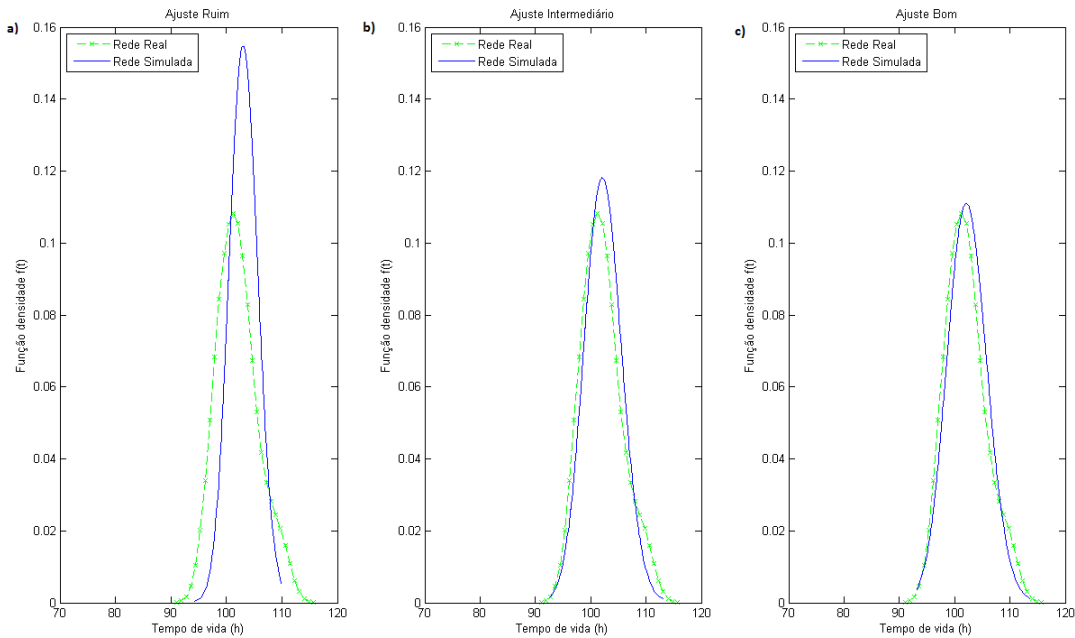


Figura 20 – Comparação entre as funções densidade estimadas pelo modelo log-normal e da rede real (ajustes a. ruim, b. intermediário e c. bom).

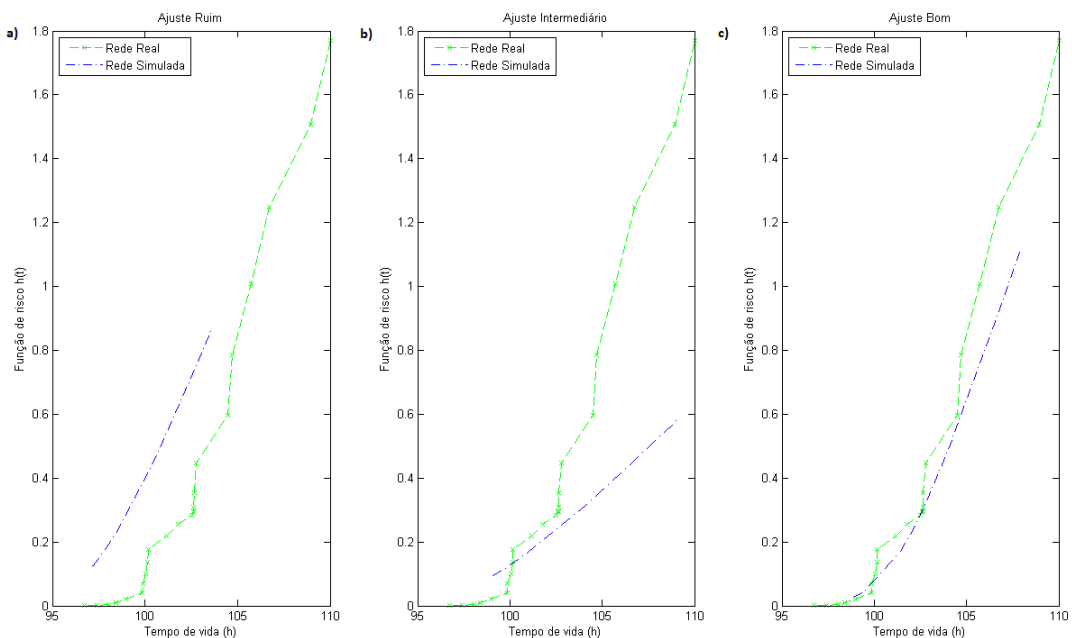


Figura 21 – Comparação entre as funções de risco estimadas pelo modelo log-normal e da rede real (ajustes a. ruim, b. intermediário e c. bom).

Por fim, analisando os *datasets* em termos da função de risco, mostramos na Figura 21 as funções de risco estimadas pelo modelo log-normal sendo comparadas à função de

risco obtida através do método não-paramétrico *kernel*. No pior ajuste (gráfico 21a), a função de risco estimada pelo modelo log-normal não se ajusta bem à função estimada pelo método não-paramétrico. O ajuste foi pior do observado no modelo Weibull. No ajuste intermediário (gráfico 21b), as funções não se ajustaram de forma satisfatória. Por fim, no gráfico 21c, as funções se ajustaram um pouco melhor, entretanto não sendo igual ao ajuste observado no modelo Weibull.

4.2 Rede com 2 sorvedouros

Nesta Seção apresentaremos os resultados obtidos para os modelos exponencial, Weibull e log-normal quando utilizados para modelar o tempo de vida da rede com 2 sorvedouros apresentada no Capítulo 3 (ver Seção 3.7.3.2).

4.2.1 Modelo Exponencial

Primeiramente, avaliamos a precisão das estimativas inferidas pelo modelo exponencial. Utilizamos os tempos de vida dos nós contidos nos 30 *datasets* e aplicamos a Equação 3.2, obtendo os resultados apresentados na Figura 22.

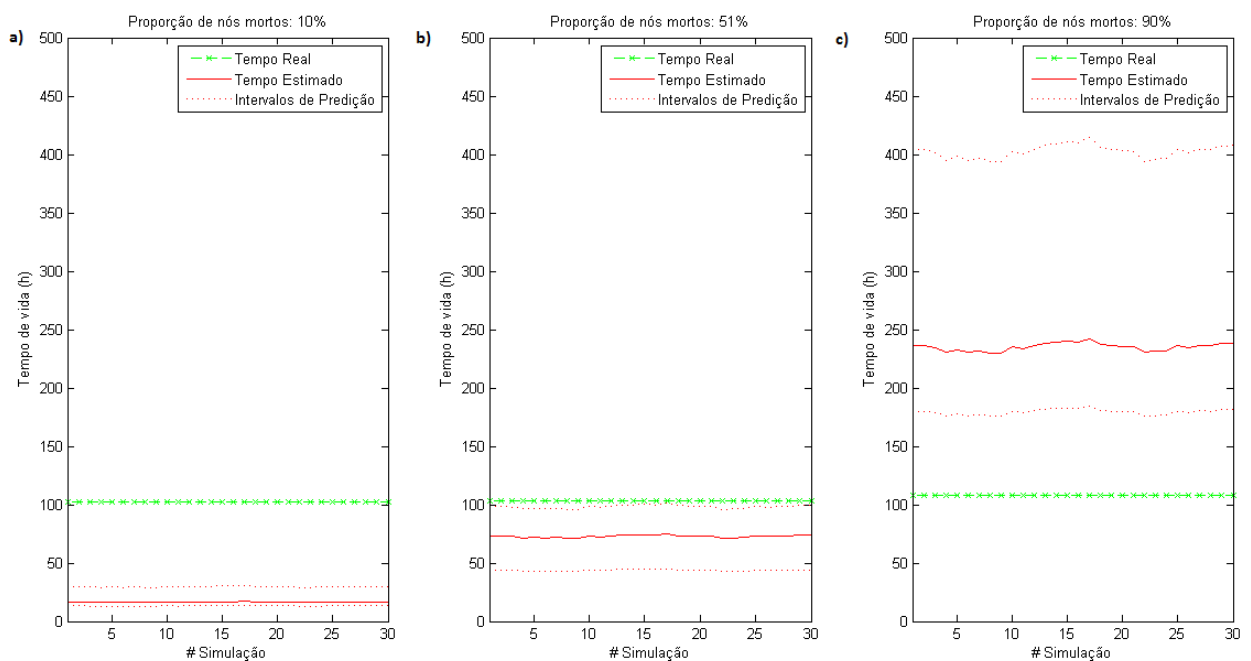


Figura 22 – Estimativas obtidas a partir do modelo exponencial para rede com 2 sorvedouros para diferentes definições de tempo de vida (a. 10%, b. 51% e c. 90%).

Analisando a Figura 22, observamos que o modelo exponencial não conseguiu estimar o tempo de vida da rede em nenhum percentil estudado, apresentando resultados

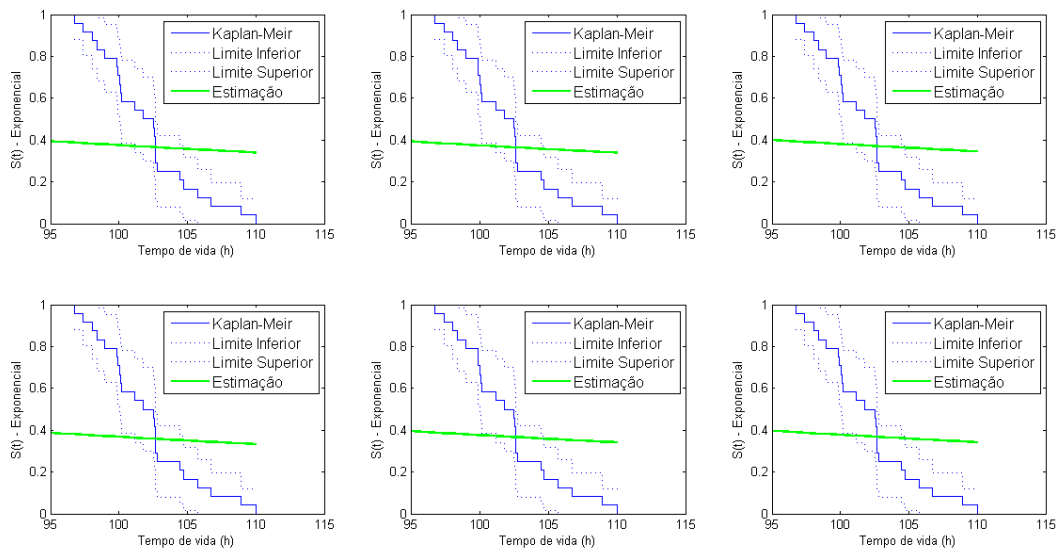


Figura 23 – Comparação entre a função estimada pelo modelo exponencial e não-paramétrico.

semelhantes aos da rede com 1 sorvedouro. Nos percentis 10 e 90, foram observados os piores resultados e no percentil 51 os melhores.

Analisamos os 30 *datasets* e para cada um estimamos a função de sobrevivência a partir do modelo exponencial e comparamos com função estimada pelo método não-paramétrico. Em todos os casos, as funções de sobrevivência obtidas a partir do modelo exponencial apresentaram resultados semelhantes. Assim como na rede com 1 sorvedouro, selecionamos 6 e mostramos os resultados na Figura 23.

Assim como observado na rede com 1 sorvedouro, o modelo exponencial não conseguiu estimar o tempo de vida da rede com 2 sorvedouros de maneira satisfatória. Além disso, o ajuste observado entre as funções de sobrevivência obtidas através do modelo exponencial e do método não-paramétrico nas duas redes, reforçam ainda mais que o modelo exponencial não é o mais indicado para modelar tempo de vida, pelo menos no domínio das redes de sensores sem fio.

4.2.2 Modelo Weibull

Ajustamos os tempos de vida dos nós à distribuição Weibull e aplicamos a Equação 3.4 para estimar o tempo de vida da rede com 2 sorvedouros, obtendo os resultados mostrados na Figura 24.

Assim como na rede com 1 sorvedouro, o modelo Weibull conseguiu se ajustar bem aos tempos de vida dos nós para esse novo cenário. No percentil 10, observa-se que as estimativas ficaram abaixo do tempo observado na rede física. Porém, em algumas simulações, o tempo observado na rede física ficou dentro do intervalo de predição. No

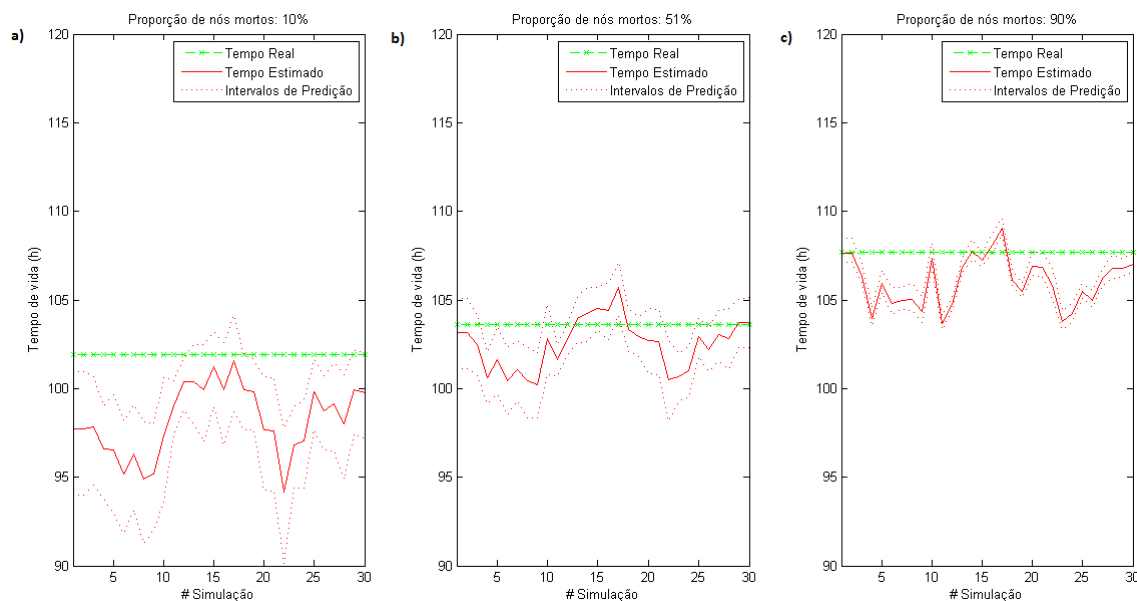


Figura 24 – Estimativas inferidas a partir do modelo Weibull para diferentes definições de tempo de vida (a. 10%, b. 51% e c. 90%).

percentil 51 as estimativas se aproximaram mais do tempo observado, porém a precisão do intervalo de predição ainda foi baixa. No percentil 90, assim como na rede com 1 sorvedouros, observamos os melhores resultados, uma vez que o intervalo de predição mostrou-se mais preciso.

Seguindo o mesmo procedimento de análise da rede anterior, analisamos os 30 *datasets* gerados a partir das simulações da rede com 2 sorvedouros a fim de compararmos as funções de sobrevivência estimadas pelo modelo Weibull com a função estimada pelo método não-paramétrico. Dentre os 30 gráficos gerados, escolhemos 3 utilizando o método gráfico (ver Seção 3.7.4), que são aqueles que apresentaram ajuste ruim, intermediário e bom, em relação ao gráfico obtido pelo método não-paramétrico, ver Figura 25. O gráfico 25a apresenta um caso de ajuste ruim. Nele, a curva de sobrevivência estimada se posiciona fora do intervalo de confiança inferido pelo método não-paramétrico. Entretanto, mesmo com um *dataset* ruim, ainda assim é possível ter percepção de como a rede provavelmente sobreviverá. No ajuste intermediário mostrado no gráfico 25b), a estimativa do modelo Weibull entrou no intervalo de confiança quando aproximadamente 90% dos nós estavam vivos e por volta de 70%. Além disso, o ajuste com a função estimada pelo método não-paramétrico não foi bom. Por fim, no gráfico 25c, as funções apresentaram um bom ajuste, principalmente quando a maioria dos nós estava mortos.

Analisamos novamente os *datasets* da segunda rede objetivando avaliar o ajuste da função densidade estimada pelo modelo weibull com a função densidade obtida através de um método não-paramétrico (Figura 26). No gráfico 26a, mesmo as funções não apresentando um bom ajuste, os picos das duas são relativamente próximos, indicando que,

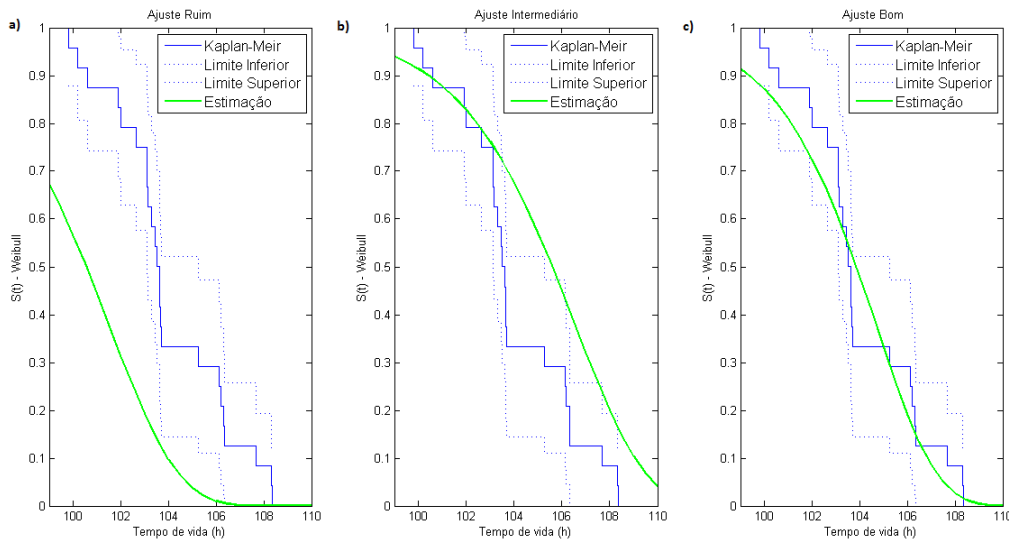


Figura 25 – Estimativas das funções de sobrevivência obtidas a partir do modelo Weibull para a rede com 2 sorvedouros (ajustes a. ruim, b. intermediário e c. bom).

mesmo com um ajuste ruim, é possível conhecer o intervalo aproximado onde a maioria dos nós irão morrer. Nos outros dois casos, os ajustes foram semelhantes e os picos das funções estimadas pelo modelo Weibull se mantiveram próximos ao pico da função estimada pelo método não-paramétrico.

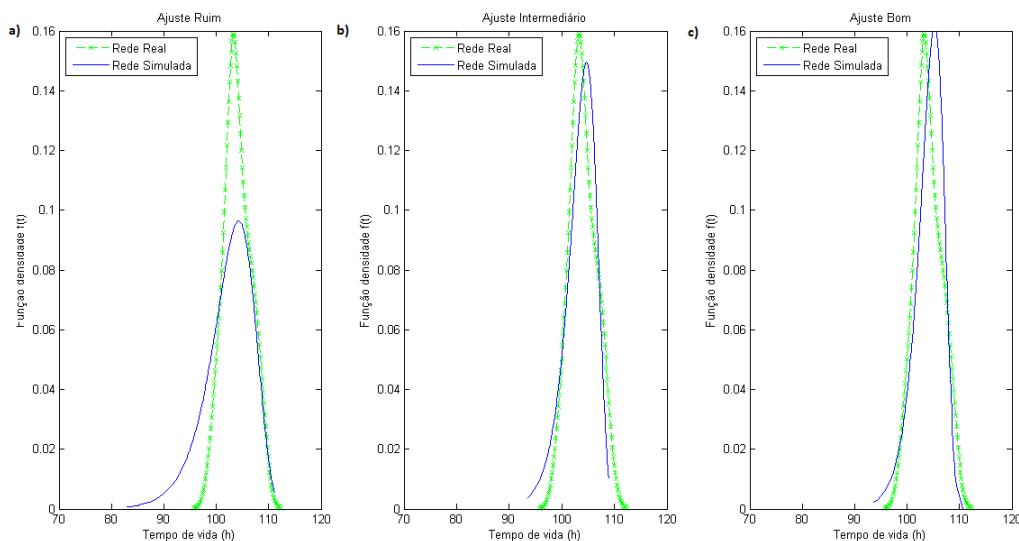


Figura 26 – Estimativas das funções densidade obtidas a partir do modelo Weibull para a rede com 2 sorvedouros (ajustes a. ruim, b. intermediário e c. bom).

Por fim, analisando novamente os *datasets* em termos da função de risco, mostramos na Figura 27, as funções de risco estimadas pelo modelo Weibull sendo comparadas à função de risco obtida através do método não-paramétrico. No gráfico 27a, podemos observar que as funções não se ajustaram bem. Entretanto, a função estimada pelo modelo Weibull apresentou uma taxa de crescimento semelhante a função estimada pelo método

não-paramétrico. No gráfico 27b, foi observado um melhor ajuste e é possível observar que a taxa de falha estimada pelo modelo Weibull se aproximou da estimativa inferida pelo método não-paramétrico, porém ela não acompanhou o crescimento dela. E finalmente, no gráfico 27c, podemos observar que as funções apresentaram um bom ajuste, o que também aconteceu na rede com 1 sorvedouro.

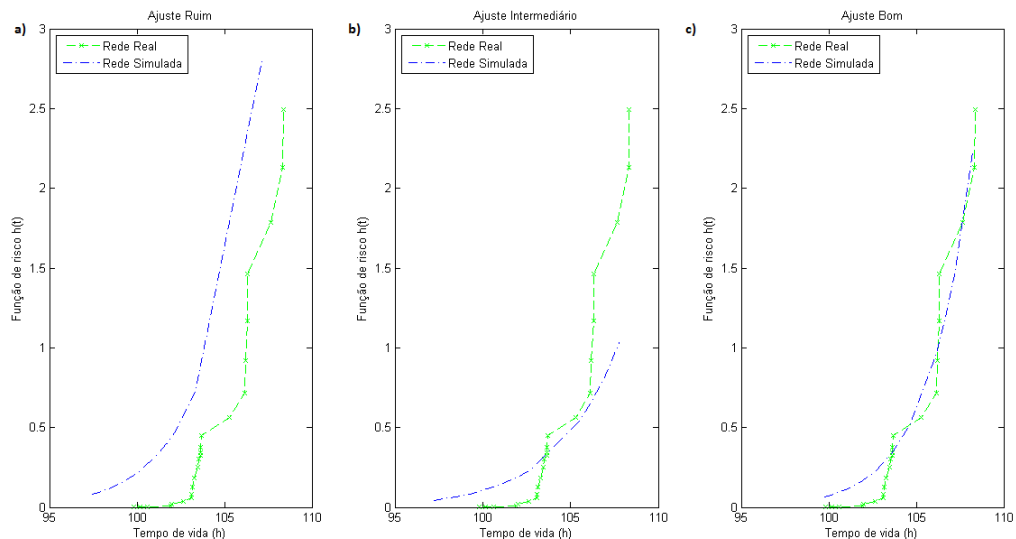


Figura 27 – Estimativas das funções de risco obtidas a partir do modelo Weibull para a rede com 2 sorvedouros (ajustes a. ruim, b. intermediário e c. bom).

4.2.3 Modelo log-normal

Ajustamos os tempos de vida dos nós à distribuição log-normal e aplicamos a Equação 3.4 para estimar o tempo de vida da rede com 2 sorvedouros, obtendo os resultados mostrados na Figura 28.

Analisando a Figura 28, observamos o mesmo comportamento da rede com 1 sorvedouro, ou seja, o modelo log-normal apresenta maior precisão de estimativa nos percentis mais baixos. Essa característica reforça nossa hipótese que o modelo log-normal é mais indicado para redes que definem k com valores menores que 0,5.

Analisando as funções de sobrevivência estimadas a partir do modelo log-normal na Figura 29, observamos que, mesmo utilizando um *dataset* ruim, (gráfico 29a), ainda assim o modelo log-normal indica uma aproximação, com erro máximo de 4 horas, da sobrevivência da rede física. No ajuste intermediário (gráfico 29b), a função de sobrevivência estimada entra em alguns instantes no intervalo de confiança inferido pelo método não-paramétrico. Nesse caso, o erro máximo de estimação foi de aproximadamente 2 horas. Por fim, no gráfico 29c, mostramos um caso de ajuste bom. Nele, as funções se ajustaram bem, mesmo a função estimada pelo modelo log-normal indicando um tempo de vida maior do observado na rede física.

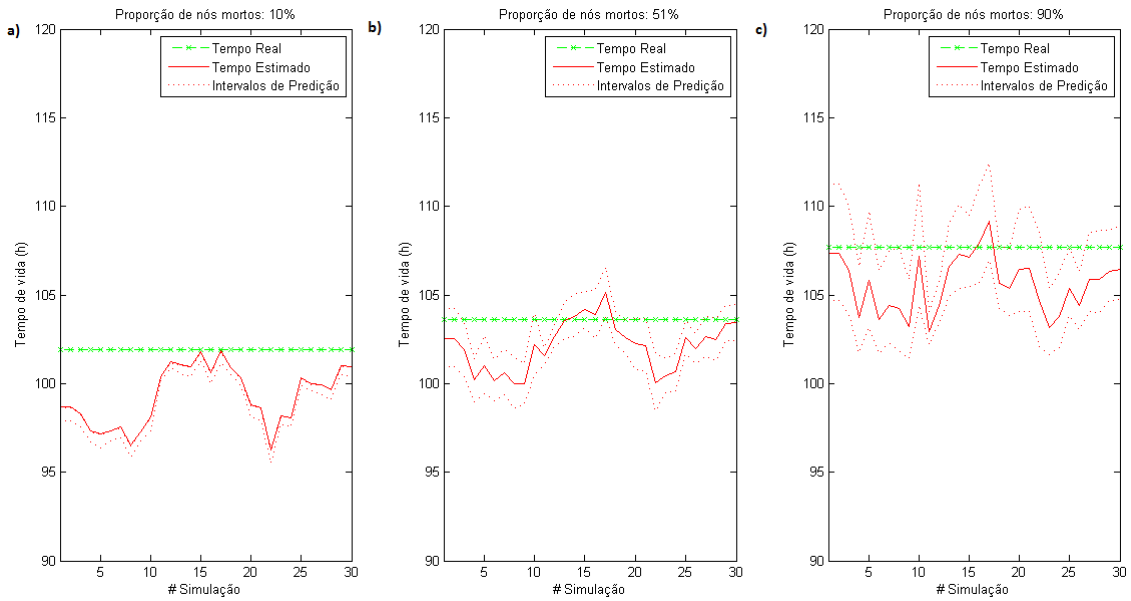


Figura 28 – Estimativas obtidas a partir do modelo log-normal para diferentes definições de tempo de vida (a. 10%, b. 51% e c. 90%).

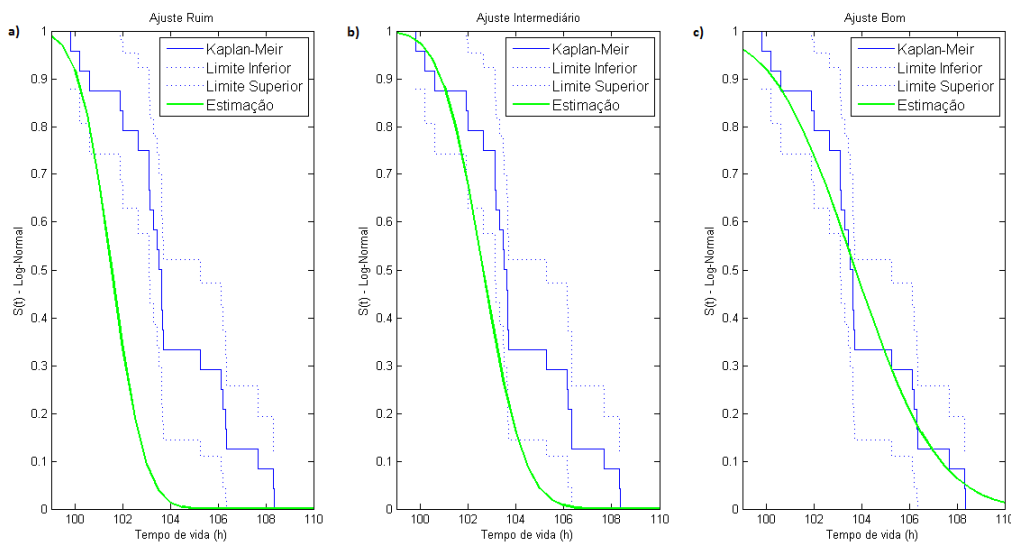


Figura 29 – Estimativas das funções de sobrevivência obtidas a partir do modelo log-normal para a rede com 2 sorvedouros (ajustes a. ruim, b. intermediário e c. bom).

Analisando agora as funções densidade, mostradas na Figura 30, estimadas pelo modelo log-normal, observamos que mesmo com ajuste ruim (gráfico 30a), podemos identificar, aproximadamente, o intervalo cuja maior quantidade de nós irá morrer. Nos casos de ajustes intermediário (gráfico 30b) e bom (gráfico 30c), os instantes de maior falha indicados pelo modelo log-normal ficaram bastante próximos do observado na rede física.

Por fim, comparamos a função de risco estimada pelo modelo log-normal com a

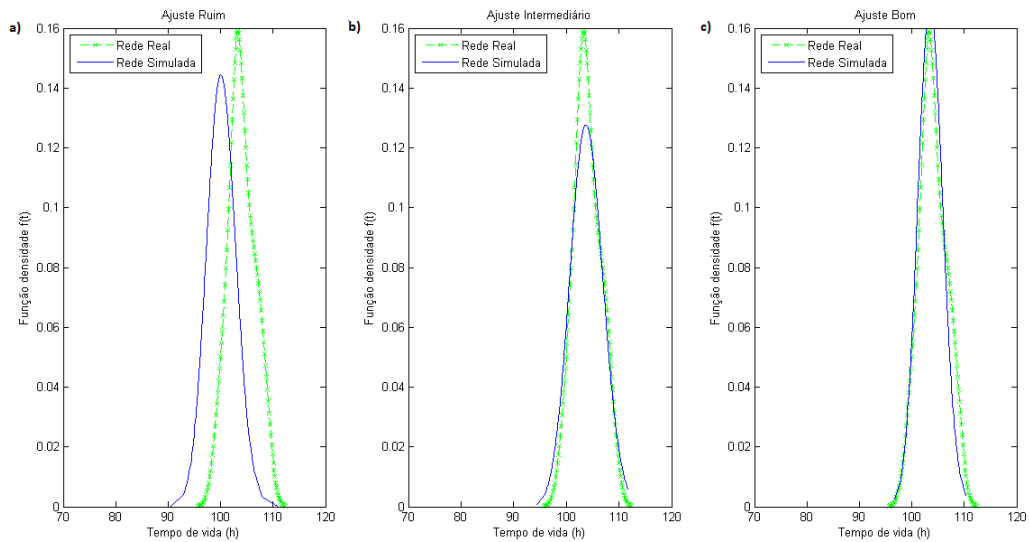


Figura 30 – Estimativas das funções densidade obtidas a partir do modelo log-normal para a rede com 2 sorvedouros (ajustes a. ruim, b. intermediário e c. bom).

função estimada através do método não-paramétrico, ver Figura 31. O resultado obtido foi semelhante ao observado na rede com 1 sorvedouro, ou seja, o modelo log-normal não estima de maneira satisfatória a função de risco a partir dos tempos de vida dos nós observados no simulador.

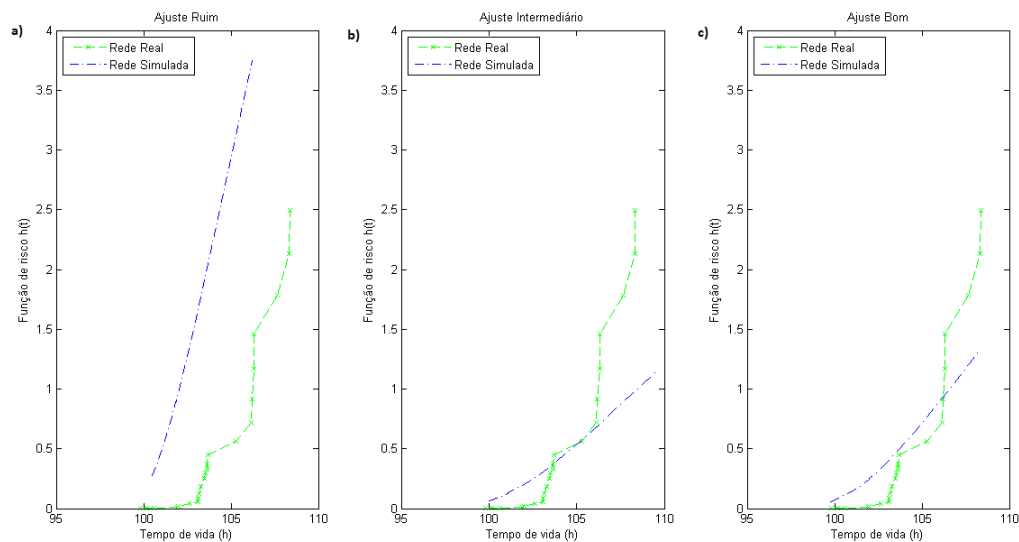


Figura 31 – Estimativas das funções de risco obtidas a partir do modelo log-normal para a rede com 2 sorvedouros (ajustes a. ruim, b. intermediário e c. bom).

4.3 Considerações sobre o modelo exponencial

Através da análise dos resultados expostos anteriormente, percebe-se que o modelo exponencial não foi adequado ao modelar os tempos de vida dos nós da rede utilizada

nos dois experimentos realizados. Dois motivos podem ser ressaltados para justificar essa afirmação. Primeiro, o modelo exponencial considera a taxa de morte dos nós constante, ou seja, a chance de que um nó venha a morrer não tem relação nenhuma com a quantidade de tempo que esse dispositivo está ligado, o que não condiz com a realidade observada. Essa propriedade é conhecida como falta de memória da distribuição exponencial. Segundo, como a distribuição exponencial possui somente 1 parâmetro, essa quantidade aparentemente não se mostrou suficiente para modelar os tempos de vida dos nós.

A partir dos resultados obtidos até agora, tanto para a rede com 1 sorvedouro como para a rede com 2, a distribuição exponencial não conseguiu modelar o tempo de vida dos nós. Vale lembrar que a proposta apresentada por [Le et al. \(2010\)](#) utilizava o modelo exponencial para modelar o tempo de vida de uma rede de sensores sem fio em diferentes topologias. Porém, como observado neste trabalho, o modelo exponencial não apresenta bons resultado e dessa forma não é o mais indicado.

4.4 Considerações sobre o modelo Weibull

Com base nos resultados obtidos mostrados anteriormente, percebeu-se que o modelo Weibull alcançou melhores resultados do que o modelo exponencial ao modelar a sobrevivência das redes avaliadas. Isso se deve ao fato que a distribuição Weibull consegue assumir uma grande variedade de formas, seja com taxa de falha constante, decrescente ou crescente. Como observando nos resultados expostos, mesmo no pior caso, é possível inferir estimativas de sobrevivência de uma rede real com uma taxa de erro aceitável. Por fim, sua utilização para modelar o tempo de vida de nós de uma rede de sensores é mais indicada em aplicações onde o percentil de nós mortos k , que define o tempo de vida da rede, é maior do que 0,5.

4.4.1 Considerações sobre o modelo log-normal

Através da análise dos resultados obtidos pelo modelo log-normal, observamos que ele apresenta melhores resultados que o modelo exponencial. Em termos das estimativas do tempo de vida da rede obtidas através da Equação 3.4, ficou evidente que esse modelo é mais indicado quando o valor de k , que define a proporção de nós mortos para que a rede seja considerada como morta, é menor que 0,5. Além disso, esse modelo apresentou boas estimativas da função de sobrevivência e da função densidade, assim como no modelo Weibull. Entretanto, em termos de estimativa da função de risco, as estimativas foram piores quando comparadas as estimativas inferidas pelo modelo Weibull. Isso é um possível indicativo que, quando se pretende inferir a taxa de falha instantânea dos nós de uma rede de sensores, esse modelo não é adequado.

4.5 Resumo do capítulo

Nesse capítulo mostramos os resultados das análises de sobrevivência realizadas nos datasets gerados a partir das simulações da rede com 1 e 2 sorvedouros, objetivando estimar a sobrevivência da rede real antes da sua implantação física. Testamos três modelos probabilísticos: exponencial, Weibull e log-normal, dos quais o exponencial foi o que apresentou piores resultados tanto em termos de estimativa quanto de ajuste. Os modelos Weibull e log-normal apresentaram resultados semelhantes e ambos conseguem se ajustar ao tempo de vida dos nós da rede. Porém, em termos das estimativas inferidas pelas Equações 3.3 e 3.4, o modelo Weibull apresentou uma melhor precisão quando o valor de k é maior que 0,5. Por outro lado, o modelo log-normal apresentou uma maior precisão quando o valor de k é menor que 0,5. Quando o valor de k é exatamente 0,5, os dois modelos apresentam precisões semelhantes. No próximo capítulo apresentamos as conclusões desta dissertação, destacando nossas principais contribuições e apontando potenciais trabalhos futuros.

5 Conclusões

Neste trabalho, propomos a utilização da análise de sobrevivência em redes de sensores sem fio com objetivo de avaliar estatisticamente o desempenho de uma rede em ambiente simulado antes da sua implantação física e real. Para isso, avaliamos os modelos exponencial, Weibull e log-Normal na perspectiva de melhorar a estimativa do tempo de vida e o planejamento operacional de uma rede de sensores sem fio. A abordagem proposta indica o momento mais propício para manutenção e eventuais reparos na rede objetivando prolongar o seu tempo de vida.

5.1 Contribuições

A contribuição central desta dissertação é concepção de uma abordagem de uso de Análise de Sobrevivência no domínio das RSSF, propiciando meios para responder aos questionamentos sobre (i) quantos nós sensores irão sair de operação durante o tempo de vida de uma RSSF, pois uma vez definido o modelo que melhor se ajusta aos tempos de vida dos nós, a função de sobrevivência $S(t)$ (vide Capítulos 2, 3 e 4) nos permite avaliar a proporção de nós mortos ao longo do tempo; (ii) em qual intervalo de tempo a maior parte dos nós vai sair de operação, pois o pico da função densidade de probabilidade $f(t)$ indica esse intervalo (vide Capítulos 2, 3 e 4) e (iii) por quanto tempo a rede permanecerá em funcionamento, pois foram propostas equações baseadas nas distribuições paramétricas exponencial, Weibull e log-Normal. Tal abordagem visa aprimorar as estimativas do tempo de vida de uma RSSF e, conseqüentemente, melhorar seu planejamento operacional. Outras contribuições desta dissertação são:

- Mapeamento de conceitos inerentes à Análise de Sobrevivência, tais como tempo de vida, funções de sobrevivência, censura, estimação, para o contexto das RSSF;
- Especificação de um modelo gerador de cargas iniciais aleatórias para nós em um ambiente simulado;
- Análise de modelos probabilísticos aplicados na modelagem de tempo de vida de redes de sensores sem fio.

5.2 Produção científica

Publicamos o artigo intitulado "**Um Algoritmo Distribuído para Eleição de Líderes de Clusters Semânticos em Redes de Sensores sem Fio**" ([HERMETO et](#)

al., 2013b), premiado com o 2o lugar no V Simpósio Brasileiro de Computação Ubíqua e Pervasiva (SBCUP) em julho/2013. Desta premiação veio o convite para submissão de uma versão estendida, intitulada "**A Distributed Algorithm for Semantic Collectors Election in Wireless Sensors Networks**"(HERMETO et al., 2013a).

5.3 Estudos Futuros

No decorrer desta dissertação, foram identificadas algumas questões que ainda necessitam ser aprofundadas e solucionadas. São apostadas aqui questões consideradas relevantes tanto para o emprego utilização da análise de sobrevivência no domínio das redes de sensores sem fio como para a extensão de suas funcionalidades. Dessa forma, é interessante investigar uma abordagem de utilização de mecanismos de desligamento dos rádios dos dispositivos, juntamente com estratégias de redução de tempo de experimento.

As redes implantadas variaram somente na quantidade de nós sorvedouros, e pelo resultados mostrados no Capítulo 4, isso não influenciou muito no tempo de vida da rede. Acreditamos que isso seja motivado pelo fato dos dispositivos manterem seus rádios sempre ligados, deixando os nós com as mesmas condições nas duas redes. Dessa forma, faz-se necessário a ampliação dos cenários de experimentos, juntamente com a aplicação de técnicas de redução de energia, como clusterização ou fusão de dados, por exemplo. Além disso, é preciso avaliar também outros algoritmos de roteamento e de acesso ao meio.

Embora a abordagem apresentada nesta dissertação seja proposta para redes de sensores, o estudo foi limitado a um só tipo de equipamento de *hardware* (MicaZ), de Sistema Operacional (Contiki) e de simulador (Cooja). Dessa maneira, é relevante a verificação se as estimativas ainda são consistentes utilizando outras plataformas de *hardware* (Arduino, Tmote Sky, Z1) e *software* (TinyOS).

Nesta dissertação avaliamos apenas 3 distribuições paramétricas. Outras distribuições surgem com potencial de modelar o tempo de vida da rede, são elas: Log-Logística, Gama e Birnbaum-Saunders, utilizada para modelar falhas oriundas de um processo de fadiga. Além disso, é relevante modelar o tempo de vida da rede em função de outras variáveis aleatórias que possuam relação causa-efeito, como por exemplo a interferência de outros dispositivos (roteadores wifi, celulares), surgindo assim os modelos de regressão.

Por fim, no Capítulo 2, foi apresentado o conceito de dados censurados, que consiste na não possibilidade de determinar precisamente o tempo de vida de participantes de um determinado experimento de sobrevivência. Esse tipo de dado também é possível de ser observado nas redes de sensores sem fio, quando um nó próximo ao sorvedouro, que é responsável por repassar dados oriundos dos nós mais distantes, morre primeiro. Isso faz com que os nós mais distantes, embora vivos, fiquem incomunicáveis. Porém, determinar essa situação não é trivial, pois os nós procuram novas rotas na ocorrência dessa situação.

Para determinar a ocorrência de censura de dados, seria necessário monitorar, a todo momento, todos os nós da rede a fim de determinar se não existem mais rotas disponíveis ao sorvedouro e que os nós mais distantes ainda estão vivos. Dito isso, é preciso investigar como inserir a questão dos dados censurados no domínio das RSSF.

Apêndice - Tempos de vida dos nós nos dois experimentos

Tabela 2 – Tempos que indicam últimos registros de vida dos nós da rede do cenário 1.

| Nó | Tempo (h) | Nó | Tempo (h) | Nó | Tempo (h) |
|-----------|------------------|-----------|------------------|-----------|------------------|
| 2 | 98,41 | 10 | 101,78 | 19 | 99,88 |
| 3 | 98,03 | 11 | 102,78 | 21 | 105,73 |
| 4 | 96,73 | 12 | 100,16 | 105 | 106,73 |
| 5 | 110,01 | 13 | 99,86 | 106 | 108,95 |
| 6 | 104,48 | 14 | 104,7 | 107 | 102,63 |
| 7 | 102,51 | 16 | 102,65 | 108 | 100,05 |
| 8 | 102,6 | 17 | 97,4 | 109 | 102,63 |
| 9 | 98,98 | 18 | 101,18 | 110 | 100,13 |

Tabela 3 – Tempos que indicam últimos registros de vida dos nós da rede do cenário 2.

| Nó | Tempo (h) | Nó | Tempo (h) | Nó | Tempo (h) |
|-----------|------------------|-----------|------------------|-----------|------------------|
| 2 | 101,90 | 10 | 103,64 | 19 | 103,11 |
| 3 | 99,80 | 11 | 105,27 | 21 | 103,65 |
| 4 | 101,18 | 12 | 103,14 | 105 | 103,29 |
| 5 | 106,13 | 13 | 102,63 | 106 | 108,31 |
| 6 | 108,35 | 14 | 106,32 | 107 | 103,70 |
| 7 | 103,50 | 16 | 106,18 | 108 | 101,61 |
| 8 | 107,67 | 17 | 101,99 | 109 | 103,45 |
| 9 | 106,33 | 18 | 103,63 | 110 | 103,11 |

Referências

- BABULAL, K. S.; TEWARI, R. R. Cross layer design with link and reliability analysis for wireless sensor network. *2011 Nirma University International Conference on Engineering*, Ieee, p. 1–5, dez. 2011. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6153250>>.
- CERPA, A.; MEMBER, S.; ESTRIN, D. ASCENT: Adaptive Self-Configuring sEnor Networks Topologies. v. 3, n. 3, p. 1–14, 2004.
- CHANG, J.; TASSIULAS, L. Maximum Lifetime Routing in Wireless Sensor Networks. *IEEE/ACM Transactions on Networking*, v. 12, n. 4, p. 609–619, ago. 2004. ISSN 1063-6692. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1331424>>.
- CHEN, I.; WANG, Y. Reliability Analysis of Wireless Sensor Networks with Distributed Code Attestation. *IEEE Communications Letters*, v. 16, n. 10, p. 1640–1643, out. 2012. ISSN 1089-7798. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6307789>>.
- CHENG, P.; CHUAH, C. Energy-aware node placement in wireless sensor networks. *IEEE Global Telecommunications Conference, 2004. GLOBECOM '04.*, Ieee, v. 5, p. 3210–3214, 2004. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1378943>>.
- CHEUNG, G. S.; LEE, A. H.; WONG, M. C. Suitability of Time Estimates for Survival Analysis of Endodontic Treatment. *Journal of Endodontics*, Elsevier Ltd, p. 1–4, jan. 2013. ISSN 00992399. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0099239912012083>>.
- CHUNG, C.; SEHMIDT, P.; WITTE, A. D. Survival Analysis : A Survey. v. 7, n. i, 1991.
- COLOSIMO, E.; GIOLO, S. *Análise de sobrevivência aplicada*. Edgard Blücher, 2006. (ABE - Projeto Fisher). ISBN 9788521203841. Disponível em: <<http://books.google.com.br/books?id=g0-uOgAACAAJ>>.
- DIETRICH, I.; DRESSLER, F. On the lifetime of wireless sensor networks. *ACM Transactions on Sensor Networks*, v. 5, n. 1, p. 1–39, fev. 2009. ISSN 15504859. Disponível em: <<http://portal.acm.org/citation.cfm?doid=1464420.1464425>>.
- DOOHAN, N. V.; MISHRA, D. K.; TOKEKAR, S. Reliability Analysis for Wireless Sensor Networks Considering Environmental Parameters Using MATLAB. *2011 Third International Conference on Computational Intelligence, Communication Systems and Networks*, Ieee, p. 99–102, jul. 2011. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6005662>>.
- DUNKELS, A. Rime — a lightweight layered communication stack for sensor networks. In: *Proceedings of the European Conference on Wireless Sensor Networks (EWSN), Poster/Demo session*. Delft, The Netherlands: [s.n.], 2007. Disponível em: <<http://dunkels.com/adam/dunkels07rime.pdf>>.

- DUNKELS, A.; GRONVALL, B.; VOIGT, T. Contiki - a lightweight and flexible operating system for tiny networked sensors. *29th Annual IEEE International Conference on Local Computer Networks*, IEEE (Comput. Soc.), p. 455–462, 2004. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1367266>>.
- GONDOS, A.; BRAY, F.; BREWSTER, D.; COEBERGH, J.; HAKULINEN, T.; JANSSEN, M.; KURTINAITIS, J.; BRENNER, H. Recent trends in cancer survival across Europe between 2000 and 2004: a model-based period analysis from 12 cancer registries. *European journal of cancer (Oxford, England : 1990)*, v. 44, n. 10, p. 1463–75, jul. 2008. ISSN 0959-8049. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/18455387>>.
- HERMETO, R.; KRIDI, D.; ROCHA, A.; GOMES, D. A distributed algorithm for semantic collectors election in wireless sensors networks. *Journal of Applied Computing Research*, 2013.
- HERMETO, R.; KRIDI, D.; ROCHA, A.; GOMES, D. Um Algoritmo Distribuído para Eleição de Líderes de Clusters Semânticos em Redes de Sensores sem Fio. *V Simpósio Brasileiro de Computação Ubíqua e Pervasiva*, 2013.
- HUANG, M.; YU, S. Gifts in a Romantic Relationship: A Survival Analysis. *Journal of Consumer Psychology*, v. 9, n. 3, p. 179–188, jul. 2000. ISSN 15327663. Disponível em: <http://www.crossref.org/deleted_DOI.html>.
- KIM, D. S.; GHOSH, R.; TRIVEDI, K. S. A Hierarchical Model for Reliability Analysis of Sensor Networks. *2010 IEEE 16th Pacific Rim International Symposium on Dependable Computing*, Ieee, p. 247–248, dez. 2010. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=5703260>>.
- LE, Z.; BECKER, E.; KONSTANTINIDES, D. G.; DING, C.; MAKEDON, F. Modeling reliability for wireless sensor node coverage in assistive testbeds. *Proceedings of the 3rd International Conference on Pervasive Technologies Related to Assistive Environments - PETRA '10*, ACM Press, New York, New York, USA, p. 1, 2010. Disponível em: <<http://portal.acm.org/citation.cfm?doid=1839294.1839349>>.
- LEE, J.; KRISHNAMACHARI, B.; KUO, C. Aging analysis in large-scale wireless sensor networks. *Ad Hoc Networks*, v. 6, n. 7, p. 1117–1133, set. 2008. ISSN 15708705. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S157087050700159X>>.
- MASTEN, S. V.; FOSS, R. D. Long-term effect of the North Carolina graduated driver licensing system on licensed driver crash incidence: a 5-year survival analysis. *Accident; analysis and prevention*, Elsevier Ltd, v. 42, n. 6, p. 1647–52, nov. 2010. ISSN 1879-2057. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/20728613>>.
- MURTHYG, S.; D'SOUZA, R. Reliability Analysis of Route Redundancy Model for Energy Efficient Node Disjoint Multipath Routing in Wireless Sensor Networks. *Procedia Engineering*, v. 38, n. may 1877, p. 1487–1494, jan. 2012. ISSN 18777058. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S1877705812020966>>.
- NAKAMURA, E.; LOUREIRO, A.; FRERY, A. Information fusion for wireless sensor networks. *ACM Computing Surveys*, v. 39, n. 3, p. 9–es, set. 2007. ISSN 03600300. Disponível em: <<http://portal.acm.org/citation.cfm?doid=1267070.1267073>>.
- OSTERLIND, F. A Sensor Network Simulator for the Contiki OS. 2006.

ROCHA, A.; PIRMEZ, L.; DELICATO, F. C.; LEMOS, E.; SANTOS, I.; GOMES, D.; SOUZA, J. WSNs clustering based on semantic neighborhood relationships. *Computer Networks*, Elsevier B.V., v. 56, n. 5, p. 1627–1645, mar. 2012. ISSN 13891286. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S1389128612000382>>.

SEAH, W. K.; EU, Z. A.; TAN, H. Wireless sensor networks powered by ambient energy harvesting (WSN-HEAP) - Survey and challenges. *2009 1st International Conference on Wireless Communication, Vehicular Technology, Information Theory and Aerospace & Electronic Systems Technology*, Ieee, p. 1–5, maio 2009. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=5172411>>.

TERAWAKI, Y.; KATSUMI, T.; DUCROCQ, V. Development of a survival model with piecewise Weibull baselines for the analysis of length of productive life of Holstein cows in Japan. *Journal of dairy science*, v. 89, n. 10, p. 4058–65, out. 2006. ISSN 1525-3198. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/16960082>>.

TIAN, D.; AVENUE, K. E.; GEORGANAS, N. D. A Coverage-Preserving Node Scheduling Scheme for Large Wireless Sensor Networks. 2000.

VASAR, C.; PROSTEAN, O.; FILIP, I.; ROBU, R.; POPESCU, D. A reliability analysis for wireless sensor networks in a wind farm. *2009 XXII International Symposium on Information, Communication and Automation Technologies*, Ieee, p. 1–5, out. 2009. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=5348408>>.

VASAR, C.; PROSTEAN, O.; FILIP, I.; ROBU, R.; POPESCU, D. Markov models for wireless sensor network reliability. *2009 IEEE 5th International Conference on Intelligent Computer Communication and Processing*, Ieee, p. 323–328, ago. 2009. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=5284742>>.

WANG, C.; XING, L.; VOKKARANE, V. M.; DARTMOUTH, N. Reliability Analysis of Wireless Sensor Networks Using Different Network Topology Characteristics. p. 12–16, 2012.

WANG, C.; XING, L.; VOKKARANE, V. M.; SUN, Y. Reliability Modeling of Wireless Sensors. 2013.

WOODALL, C.; GRAMBSCH, P.; THOMAS, W. Applying survival analysis to a large-scale forest inventory for assessment of tree mortality in Minnesota. *Ecological Modelling*, v. 189, n. 1-2, p. 199–208, nov. 2005. ISSN 03043800. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S030438000500195X>>.