

Dissertação de Mestrado

**Predição de dados de sensoriamento visando
eficiência energética através da redução de
transmissão de dados em Redes de Sensores Sem
Fio**

Charles Mariano Pedrosa de Almeida
charles.pedrosa@gmail.com

Orientador:
Dr. André Luiz Lins Aquino

Maceió, dezembro de 2019

Charles Mariano Pedrosa de Almeida

**Predição de dados de sensoriamento visando
eficiência energética através da redução de
transmissão de dados em Redes de Sensores Sem
Fio**

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-Graduação em Modelagem Computacional de Conhecimento do Instituto de Computação da Universidade Federal de Alagoas.

Orientador: Dr. André Luiz Lins Aquino

Catálogo na fonte
Universidade Federal de Alagoas
Biblioteca Central
Divisão de Tratamento Técnico

Bibliotecária: Taciana Sousa dos Santos – CRB-4 – 2062

A447p Almeida, Charles Mariano Pedrosa de.
Predição de dados de sensoriamento visando eficiência energética através da redução de transmissão de dados em redes de sensores sem fio / Charles Mariano Pedrosa de Almeida. – 2020.
48 f. : il., tabs.

Orientador: André Luiz Lins Aquino.
Dissertação (mestrado em Modelagem Computacional do Conhecimento) – Universidade Federal de Alagoas. Instituto de Computação. Maceió, 2019.

Bibliografia: f. 44-48.

1. Redes de sensores sem fio. 2. Eficiência energética. 3. Modelos de predição. I. Título.

CDU: 004.7

Folha de Aprovação

Charles Mariano Pedrosa de Almeida

Predição de Dados de Sensoriamento Visando Eficiência Energética em Redes de Sensores Sem Fio

Dissertação submetida ao corpo docente do Programa de Pós-Graduação em Modelagem Computacional de Conhecimento da Universidade Federal de Alagoas e aprovada em 20 de dezembro de 2019.

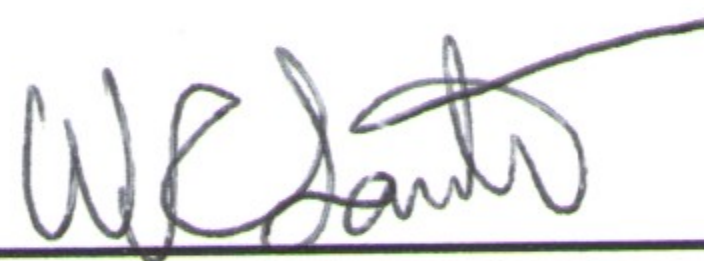


Prof. Dr. André Luiz Lins de Aquino

Instituto de Computação - UFAL

Orientador

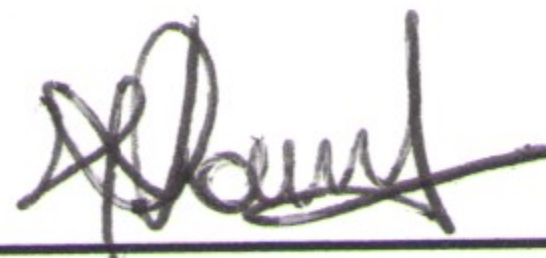
Banca Examinadora:



Prof. Dr. Wellinsílvia Costa dos Santos

Centro de Tecnologia – UFAL

Examinador Externo



Prof. Dr. Heitor Soares Ramos Filho

Departamento de Ciência da Computação – UFMG

Examinador Externo

RESUMO

As redes de sensores sem fio (RSSF) já são objeto de interesse dos pesquisadores e estão se tornando cada vez mais integradas aos sistemas domésticos, comerciais, industriais, etc. No entanto, devido às suas próprias características, o problema da restrição e gerenciamento de energia na própria rede é um dos principais pontos a serem equalizados. Neste contexto, existem várias abordagens para proporcionar eficiência energética, e diante disso, este trabalho tem como objetivo comparar modelos de predição de dados de sensoriamento em redes de sensores sem fio com a finalidade de economizar energia na transmissão de dados. Modelos ARIMA, SVM, MLP/ANN e RNN/LSTM foram utilizados em uma aplicação de coleta de dados de temperatura e avaliados quanto à economia de energia proporcionada. As medições foram realizados por dispositivos reais e foi possível observar o desempenho dos modelos para um conjunto de dados de sensoriamento em um ambiente de escritório. Para este trabalho, o modelo SVM apresentou melhor desempenho em relação aos demais em termos de eficiência energética.

Palavras-chave: Redes de sensores sem fio. RSSF. ARIMA. SVM. ANN. RNN. LSTM. Eficiência energética. Modelos de predição.

ABSTRACT

Wireless sensor networks (RSSF) are already of interest to researchers and are becoming increasingly integrated with home, commercial, industrial, etc. systems. However, due to its own characteristics, the problem of power restriction and management in the grid itself is one of the main points to be equalized. In this context, there are several approaches to provide energy efficiency, and in view of this, this work aims to compare prediction models of sensing data in wireless sensor networks in order to save energy in data transmission. ARIMA, SVM, MLP/ANN and RNN/LSTM models were used in a temperature data collection application and evaluated for the energy savings provided. The measurements were performed by real devices and it was possible to observe the performance of the models for a sensing data set in an office environment. For this work, the SVM model presented better performance compared to the others in terms of energy efficiency.

Keywords: Wireless sensor networks. WSN. ARIMA. SVM. ANN. RNN. LSTM. Energy efficiency. Prediction models.

AGRADECIMENTOS

Agradeço aos amigos André Aquino e Geymerson Ramos pelo apoio e ajuda ao longo deste trabalho. Agradeço também a todas as pessoas importantes nesta etapa da minha vida.

Charles Mariano Pedrosa de Almeida

LISTA DE FIGURAS

3.1	Estrutura de Rede Neural. Figura retirada de (Khashei et al., 2012).	25
3.2	Uma típica rede neural feedforward	28
3.3	Uma típica rede de blocos de memória LSTM. Figura retirada de (Kim & Won, 2018).	30
4.1	RSSF - Diagrama de aplicação.	33
4.2	Gráfico de temperaturas reais e previstas	34
4.3	Temperatura real e previsões. Coleta 2, 12 horas de amostras e $\delta = 0,3$	36
4.4	Temperatura real e previsões. Coleta 4, 12 horas de amostras e $\delta = 0,7$	36
4.5	Curva de Descarga das Baterias. Coleta 4, 24 horas de amostras e $\delta = 0,7$	38
4.6	Curva de Potência Entregue. Coleta 4, 24 horas de amostras e $\delta = 0,7$	39

SUMÁRIO

1	INTRODUÇÃO	9
1.1	Definição do Problema	9
1.2	Contribuições	10
1.3	Objetivos	10
1.4	Organização da Dissertação	11
2	LEVANTAMENTO BIBLIOGRÁFICO	12
2.1	Metodologia do Levantamento	12
2.2	Fontes de energia em RSSFs	13
2.2.1	RSSF com baterias	13
2.2.2	RSSF com coleta de energia	13
2.3	Revisão cronológica	13
2.4	Revisão conceitual	17
3	MODELOS DE PREDIÇÃO DE SÉRIES TEMPORAIS	20
3.1	Introdução	20
3.2	Modelos de Predição	21
3.2.1	Modelo ARIMA	21
3.2.2	Modelo SVM	23
3.2.3	Modelo MLP/ANN	25
3.2.4	Modelo LSTM/ANN	29
4	RESULTADOS	32
4.1	Aplicação	32
4.2	Acurácia dos Modelos	34
4.3	Número de Transmissões Evitadas	37
4.4	Eficiência Energética	38
4.5	Tempo de Execução	39
5	CONCLUSÕES	42
5.1	Considerações Finais	42
5.2	Trabalhos Futuros	43
	Referências Bibliográficas	44

INTRODUÇÃO

1.1 Definição do Problema

As redes de sensores sem fio (RSSFs) (Akyildiz et al., 2002) permitem o monitoramento e controle de variáveis físicas como temperatura, som, luz, vibração, pressão, movimento ou poluição (Ruela et al., 2009). Nas RSSFs os nós sensores possuem geralmente energia limitada e a comunicação sem fio destes sensores pode ser considerada a principal forma de consumo. Portanto, reduzir a sobrecarga de comunicação pode ser um dos métodos mais eficazes para economizar energia nestes sistemas (Liu et al., 2005).

A partir do levantamento bibliográfico foi possível identificar 5 (cinco) principais classes das técnicas de eficiência energética em RSSFs:

- Redução de dados (Liu et al., 2005);
- Protocolo de redução de sobrecarga (Huang et al., 2013);
- Roteamento energeticamente eficiente (Heinzelman et al., 2002);
- Ciclo de trabalho (Han et al., 2013);
- Controle de topologia (Santi, 2005).

A Redução dos Dados tem seu foco na redução do montante de dados produzidos, processados e transmitidos. Neste trabalho é verificado que a redução do consumo de energia pode se dar através da redução da quantidade de transmissões entre nó sensor e a estação-base. A redução será obtida através da supressão do envio de parte dos dados coletados no nó sensor e sua substituição por dados gerados em um modelo de predição na estação-base.

Quatro modelos matemáticos foram empregados para predição das séries temporais correspondentes aos dados sensoriados numa rede de sensores sem fio real que foi implantada

em um ambiente de escritório e laboratório da própria Universidade Federal de Alagoas. O trabalho busca resolver o problema de extrapolar as pesquisas já realizadas e averiguar quais os modelos que trazem um melhor desempenho do ponto de vista energético para predição de dados de sensoriamento em RSSF.

1.2 Contribuições

As principais contribuições são:

- Uma apresentação do estado da arte das técnicas de predição de séries temporais aplicadas a dados de sensoriamento em RSSF;
- Construção e especificação de um experimento real de uma RSSF com algoritmos que visam a redução da transmissão de dados e consequente eficiência energética;
- Comparação da eficiência energética e esforço computacional entre os modelos matemáticos de predição de séries temporais aplicados no experimento supracitado;
- Comparação e apresentação dos algoritmos e modelos utilizados indicando uma solução com menor consumo de energia e maior economia de recursos para aplicações que visem eficiência energética em RSSF.

1.3 Objetivos

Os principais objetivos relacionados ao trabalho são:

- Aplicar técnicas de predição de séries temporais para redução de dados numa RSSF;
- Projetar e disponibilizar as especificações e os algoritmos de uma RSSF utilizando dispositivos de baixo custo;
- Identificar as técnicas com maior eficiência energética na RSSF real com modelos matemáticos de predição de séries temporais para redução de dados de comunicação.

1.4 Organização da Dissertação

As próximas seções abordarão: no capítulo 2, o levantamento bibliográfico com o detalhamento da metodologia utilizada, revisão cronológica e conceitual. No capítulo 3, veremos detalhes dos modelos matemáticos utilizados. No capítulo 4, detalhamento da aplicação e apresentação dos resultados do experimento comparando as técnicas de predição de séries temporais aplicadas a dados de sensoriamento em RSSF. E, por fim, no capítulo 5, conclusões e sugestões para trabalhos futuros.

O capítulo apresentou a abordagem do problema foco nesta dissertação. Em seguida, foram apresentadas as contribuições e objetivos desta pesquisa. Dando sequência, o segundo capítulo apresentará o levantamento bibliográfico realizado.

2

LEVANTAMENTO BIBLIOGRÁFICO

ESSE capítulo apresenta o levantamento bibliográfico realizado dentro do tema da pesquisa. É apresentada a metodologia utilizada no levantamento, uma revisão cronológica dos principais trabalhos da área e uma revisão conceitual que leva em consideração todos os trabalhos pesquisados e contextualiza esta dissertação.

2.1 Metodologia do Levantamento

O processo de revisão bibliográfica foi iniciado em outubro de 2018 com uma pesquisa do tipo "avançada", através de palavras chaves no ISI (Web of Science) para busca de artigos em periódicos indexados e conferências. A busca realizada teve o objetivo de verificar os principais trabalhos desenvolvidos no tema, Redes de Sensores Sem Fio, que utilizam técnicas de predição de séries temporais para se ter eficiência energética com a redução de dados transmitidos. A *string* de busca utilizada foi:

- TS = (((wireless AND sensor AND (network OR networks) OR WSN)) AND (Energy AND efficient) AND (prediction))

A busca, inicialmente abrangente, retornou 272 (duzentos e setenta e dois) artigos que foram analisados e agrupados em função da abordagem na forma de redução no consumo de energia. Em seguida, foram analisados, de forma mais aprofundada, os artigos que abordavam especificamente a predição de séries temporais com o propósito de gerenciar o consumo de energia nas redes de sensores sem fio. Através do critério de leitura integral do artigo e análise da correlação com o tema da dissertação, aproximadamente 50 (cinquenta) artigos foram citados. Vale ressaltar que no decorrer da elaboração desta dissertação, em especial após a qualificação, outras pesquisas foram realizadas, com o objetivo de incorporar novas definições, atualizar o trabalho e atender novas demandas oriundas das revisões.

2.2 Fontes de energia em RSSFs

As diversas técnicas de gerenciamento de energia podem ser aplicadas em duas grandes categorias de RSSF, as redes que possuem sensores alimentados eletricamente por baterias e os sensores que coletam de outras fontes parte ou toda a sua energia. Neste linha, segue abaixo uma definição para cada tipo de rede:

2.2.1 RSSF com baterias

A maioria dos nós sensores existentes são alimentados por baterias. A existência de aplicações com consumo de energia relativamente baixo ou vida útil curta possibilitou considerar as baterias como fontes de energia viáveis em RSSFs. No entanto, não importa o quanto a energia consumida seja baixa, devido à capacidade limitada, as baterias acabarão sendo drenadas em aplicações que exigem durações operacionais mais longas (Babayo, 2017). A substituição das baterias nem sempre é uma tarefa viável.

2.2.2 RSSF com coleta de energia

As tecnologias baseadas na energia proveniente do sol fornecem energia para os nós sensores com eficiência alta, no entanto dependem do tamanho dos painéis solares associados aos sensores. Além das tecnologias solares existe também as fontes que utilizam da vibração para transformar energia. No entanto, estas fontes são temporárias e geralmente insuficiente, daí a necessidade de se ter esquemas de gerenciamento de energia para fornecer uma utilização eficiente da energia coletada.

Independente da fonte de energia utilizada na RSSF, seja por baterias, por coleta ou híbrido, a eficiência energética é fator primordial para o desempenho da rede. Seguindo esta abordagem, nas próximas seções temos uma revisão cronológica dos principais trabalhos realizados e uma revisão conceitual sobre o tema.

2.3 Revisão cronológica

2005: Em (Liu et al., 2005) o objetivo é economizar energia na coleta de informações em redes de sensores sem fio. A metodologia empregada se baseia em manter os nós sensores da transmissão de informações redundantes, através da predição pelo nó coletor (estação-base). O ARIMA é utilizado como modelo para predição, propondo um esquema de coleta de informações eficiente em termos energéticos. A eficácia do método proposto apresentado no trabalho é demonstrada com uma aplicação real baseada na plataforma MICA2.

- 2008:** O trabalho de (Wang et al., 2008) investiga o problema da eficiência energética e propõe um método de organização eficiente de energia com previsão de séries temporais. A organização das redes de sensores sem fio está formulada para rastreamento de alvo. A posição alvo futura é derivada de modelos de média móvel autorregressiva (ARMA). Os resultados experimentais verificam que a combinação do modelo ARMA e a decomposição do modo empírico podem estimar a posição alvo de forma eficiente e a economia de energia é alcançada pelo método de organização proposto.
- 2011:** A abordagem de (Moghadam & Keshmirpour, 2011) se baseia no argumento que uma das maneiras de reduzir o consumo de energia dos nós sensores é reduzir o número de transmissões sem fio entre nós por predição dupla. Nesta abordagem, o nó sorvedouro, em vez da comunicação direta, explora um modelo de séries temporais para prever leituras locais nos nós sensores com certa precisão. Existem diferentes modelos lineares e não-lineares para previsão de séries temporais. Neste artigo é introduzido um modelo de previsão híbrido que é criado a partir da combinação do modelo ARIMA e com rede neural. É apresentada uma comparação entre a eficácia dessa abordagem e os modelos híbridos anteriores.
- 2014:** No trabalho de (Amidi, 2014), para resolver as lacunas de dados e substituir dados errados, a modelagem de correlação temporal é aplicada, o que aproveita a correlação temporal e também é eficiente em termos energéticos. Nesta pesquisa, a adequação da adaptação do modelo ARIMA em um contexto de RSSF é analisada, uma vez que os requisitos tecnológicos exigem considerações especiais. A necessidade de aplicar uma técnica de suavização é explorada e a seleção de um método apropriado é determinada. Além disso, as opções disponíveis com relação à configuração do ARIMA são discutidas, em termos de obter previsões precisas. O efeito de dados históricos e a importância do tempo de vida das previsões na precisão da estimativa são adicionalmente investigados. Por fim, propõe-se um sistema adaptativo, on-line e energeticamente eficiente para manter a precisão do modelo que detecta simultaneamente *outliers* e eventos, além de substituir quaisquer dados ausentes ou errados por valores estimados.
- 2015:** No artigo de (Zhang et al., 2015) é proposto uma série de novos algoritmos de predição lineares auto-adaptativas para os nós sensores enviarem suas leituras ao nó sorvedouro ou *cluster head* quando a tecnologia de agrupamento é usada. É proposto um algoritmo de extração dinâmica para selecionar um conjunto de treinamento adequado a partir dos dados da série histórica, e então é proposto um algoritmo de busca baseado em critérios de informação para encontrar um melhor conjunto de treinamento.
- 2015:** No trabalho de (Aderohunmu et al., 2015) é proposto o SWIFTNET: um esquema de aquisição de dados reativos. Ele é construído sobre as sinergias decorrentes de uma combinação de métodos de redução de dados e esquemas de compactação de dados

que economizam energia. Particularmente, combina *compressed sensing*, predição de dados e estratégias de amostragem adaptativa.

- 2016:** No trabalho de (Raza et al., 2016) a operação neutra de energia das RSSFs pode ser alcançada explorando a ociosidade da carga de trabalho para reduzir o consumo médio de energia de cada nó abaixo da capacidade de coleta disponível. Neste trabalho é utilizada uma combinação de técnicas de projeto de baixa potência de última geração para minimizar o impacto local e global das duas principais atividades de cada nó: amostragem e comunicação. O gerenciamento dinâmico de energia é adotado para explorar modos de baixa energia durante períodos ociosos, enquanto o despertar assíncrono e a coleta de dados baseada em previsão são usados para ativar oportunisticamente os componentes de *hardware* e os nós da rede somente quando eles são estritamente necessários. Além disso, o conceito de “sensoriamento baseado em modelo” é introduzido para que as técnicas de coleta de dados baseadas em predição sejam o mais próximo possível dos elementos sensoriais.
- 2016:** No trabalho de (Arunraja et al., 2016) é mostrado que numerosas estratégias de redução de dados usam filtros adaptativos que exploram a correlação temporal entre os dados do sensor para prever os valores futuros. Assim, apenas um subconjunto de dados sensoriais é comunicado ao coletor, o resto é previsto. Os filtros de previsão sofrem de ineficiências, quando os parâmetros de filtro são inadequados para o contexto de dados específico. A eficiência de previsão e a precisão dos dados podem ser substancialmente aprimoradas pela seleção adaptativa dos parâmetros de filtro com base no contexto dos dados. No filtro proposto de tamanho de passo adaptativo e comprimento adaptativo nLMS (ASAL-nLMS), foi definido métodos de adaptação para o filtro de predição no cenário da RSSF. O filtro adaptativo proposto adapta seu comprimento de filtro com base na dinâmica de dados e adapta seu tamanho de etapa com base no estado de convergência da predição de dados.
- 2017:** No trabalho de (Jaber et al., 2017) uma técnica de redução de dados para transmissão nas RSSF é proposta. A técnica utilizada permite que cada nó sensor pesquise a variação entre as leituras coletadas em cada período com base no modelo de Kruskal-Wallis. Em seguida, o sensor seleciona um conjunto de leituras representativas em vez de enviar as leituras inteiras coletadas durante um período para o coletor.
- 2017** Em (Sachan et al., 2017) temos uma descrição do consumo de energia para os componentes de um nó sensor típico e é discutido as principais abordagens para métodos de economia de energia em redes de sensores sem fio.
- 2017:** No *survey* de (Jan et al., 2017) é discutido como os nós sem fio são agrupados em *clusters* para comunicação com eficiência energética. Nos agrupamentos, os esquemas

hierárquicos são importantes para minimizar o consumo de energia. Os esquemas hierárquicos são geralmente categorizados com abordagens baseadas em *cluster* e baseadas em grade. Em abordagens baseadas em *cluster*, os nós são agrupados em *clusters*, onde um nó de sensor com recursos é nomeado como um *cluster head* (CH), enquanto na abordagem baseada em grade a rede é dividida em redes virtuais confinadas geralmente executadas pela estação base. Este artigo destaca e discute os desafios de design para esquemas baseados em *cluster*, os importantes parâmetros de formação e a classificação de protocolos hierárquicos de *clustering*. Além disso, as técnicas existentes baseadas em *cluster* e em grade são avaliadas considerando certos parâmetros para ajudar os usuários na seleção da técnica apropriada. Além disso, um resumo detalhado desses protocolos é apresentado com suas vantagens, desvantagens e aplicabilidade em casos particulares.

- 2018:** Em (Ruan & Lu, 2018) é proposto um algoritmo de previsão de correlação espaço-temporal auto-adaptativa (SAS-TC), que combina correlação temporal e correlação espacial para predição de dados de sensoriamento em redes de sensores sem fio. O modelo adaptativo de predição cinza é usado para medir a correlação temporal de dados de sensoriamento e, em seguida, a triangulação de Delaunay é introduzida para medir a correlação espacial dos dados. O modelo de previsão de cinza adaptável é executado entre os nós membros e os *head cluster* (HC), usando a correlação temporal de dados dentro desses nós e HC para reduzir a quantidade de transmissão de dados. O modelo de correlação espacial é executado entre os HC e os nós sensores, usando a correlação espacial dos dados nos nós do membro para reduzir a quantidade de transmissão de dados.
- 2018:** Em (Zuhairy & Al Zamil, 2018) é investigado a aplicação de uma versão modificada de regressão logística multinomial (MLR) com o objetivo de utilizar características espaço-temporais de um dado ambiente para desenvolver uma estratégia de balanceamento de carga dinâmica, na qual um modelo de predição é aplicado para estimar o melhor conjunto de variáveis e sensores que poderiam ser usados como uma substituição para expandir o tempo de vida de tais redes. Ele modela as variáveis nominais nas quais os resultados são representados como uma combinação linear das variáveis preditoras.
- 2018:** Em (Abdolkarimi et al., 2018), a fim de reduzir o consumo de energia e reduzir os atrasos na entrega de pacotes nas WSNs mencionadas, duas abordagens são propostas: (1) projetar um sistema *fuzzy* completamente distribuído para determinar a elegibilidade do nó por ser *head cluster* (HC) com dois fatores de entrada, a saber: estado de um nó sensor no WSN (GSoSN) e localização de um nó sensor em relação aos nós de *gateway* móvel (LoSNRtMG). Ao definir dois fatores discutidos anteriormente, não apenas a precisão da tomada de decisão na seleção do nó HC aumenta, mas também diminui

a sobrecarga computacional; e (2) reduzir a sobrecarga de comunicação aplicando o método de predição linear para estimar as próximas localizações dos nós de *gateway* em movimento em vez da transmissão periódica de suas mensagens de localização.

Em linhas gerais, existem uma diversidade de técnicas e soluções para o problema aqui apresentado. Contudo, diferente do que apresentamos nesse trabalho, não existe um estudo comparativo aprofundado do impacto das técnicas para a predição de dados de sensoria-mento através da análise de séries temporais visando a eficiência energética em RSSFs.

2.4 Revisão conceitual

A partir do levantamento bibliográfico foi possível identificar 5 (cinco) principais classes das técnicas de eficiência energética em RSSFs. Seriam elas:

- Redução de dados;
- Protocolo de redução de sobrecarga;
- Roteamento energeticamente eficiente;
- Ciclo de trabalho;
- Controle de topologia.

Redução de dados: concentra-se em reduzir a quantidade de dados produzidos, proces-sados e transmitidos. Por exemplo, o modelo proposto neste trabalho e nos trabalhos de (Liu et al., 2005), (Wang et al., 2008) e (Moghadam & Keshmirpour, 2011) que buscam diminuir a quantidade de dados transmitidos entre o nó sensor e o nó *sink* utilizando como substituto predições dos dados sensorizados.

Em (Aquino et al., 2008), (Silva Junior et al., 2009), (Aquino, 2011), (Maia et al., 2013), (Aquino et al., 2014) são apresentadas várias abordagens diferentes que visam a redução da transmissão de dados em Redes de Sensores Sem Fio.

Protocolo de redução de sobrecarga: Existem diferentes técnicas. Em uma delas, a mesma aborda os períodos de transmissão de mensagens onde são adaptados dependendo da estabilidade da rede ou da distância até a fonte da informação transmitida. Mais generi-camente, uma abordagem de camadas cruzadas permitirá uma otimização dos protocolos de comunicação, levando em conta os requisitos da aplicação. Outra técnica, a inundação otimizada, pode contribuir significativamente para reduzir a sobrecarga e conseqüentemente os gastos com energia (Soua & Minet, 2011).

Roteamento energeticamente eficiente: os protocolos de roteamento devem ser projeta-dos com o objetivo de maximizar o tempo de vida da rede, minimizando a energia consumida

pela transmissão de ponta a ponta e evitando nós com baixa energia residual. Alguns protocolos são oportunistas, aproveitando a mobilidade do nó ou a natureza de transmissão das comunicações sem fio para reduzir a energia consumida por uma transmissão para o coletor. Outros usam coordenadas geográficas de nós para construir uma rota em direção ao destino. Outros criam uma hierarquia de nós para simplificar o roteamento e reduzir sua sobrecarga. Por fim, os protocolos centrados em dados enviam dados apenas para os nós interessados, a fim de poupar as transmissões inúteis (Soua & Minet, 2011). Um exemplo deste tipo de aplicação pode ser vista em (Abdolkarimi et al., 2018).

Ciclo de trabalho: ciclo de trabalho significa a fração de nós que estão ativos durante sua vida útil. As programações de dormindo/acordado dos nós devem ser coordenadas e acomodadas para os requisitos das aplicações específicas. Essas técnicas podem ser subdivididas. As técnicas de alta granularidade se concentram na seleção de nós ativos entre todos os sensores implantados na rede. E as técnicas de baixa granularidade lidam com o desligamento do rádio de nós ativos quando nenhuma comunicação é necessária (respectivamente, quando uma comunicação envolvendo este nó pode ocorrer). Eles são altamente relacionados ao protocolo de acesso ao meio (Soua & Minet, 2011).

Controle de topologia: concentra-se em reduzir o consumo de energia ajustando a potência de transmissão enquanto mantém a conectividade de rede. Uma nova topologia reduzida é criada com base nas informações locais (Soua & Minet, 2011).

Levando em consideração que este trabalho se encaixa dentro da classe de técnicas nomeada de **Redução de dados**, vale apresentar as três categorias que podemos ter em função dos trabalhos revisados:

- Redução de dados através de: Produção de dados;
- Redução de dados através de: Processamento de dados;
- Redução de dados através de: Comunicação dos dados.

A produção de dados tem sido explorada por pesquisadores como nos trabalhos de (Arunraja et al., 2016), (Ruan & Lu, 2018) e (Zuhairy & Al Zamil, 2018). Isso estimulou os pesquisadores a explorar a correlação temporal de dados detectados e assim surgiram técnicas de previsão. Além disso, os ambientes investigados são frequentemente dinâmicos e podem testemunhar mudanças em diferentes áreas. O desafio é representar uma imagem precisa do verdadeiro estado do mundo enquanto se faz um uso eficiente dos recursos. Isso deu origem a diferentes técnicas, tais como: técnicas baseadas em amostragem e em predição (Soua & Minet, 2011).

Processamento e comunicação dos dados. Diferentes operações nos dados coletados podem ser introduzidas durante a etapa de processamento para lidar com a escassez de recursos de energia em uma RSSF. As duas técnicas principais encontradas são a compactação

de dados e agregação de dados. Como exemplo da agregação de dados temos o trabalho de (Ruan & Lu, 2018) e (Abdolkarimi et al., 2018).

De acordo com a revisão bibliográfica apresentada o presente trabalho pode ser categorizado como uma técnica que envolve a **Produção de dados**, no caso, reduzindo sua quantidade para diminuição dos dados transmitidos. Esta técnica é pertencente à classe de eficiência energética denominada **Redução de dados**, uma vez que diminui a quantidade de dados transmitidos.

O presente capítulo apresentou o levantamento bibliográfico dentro do tema da pesquisa. Os principais trabalhos foram elencados e a relação dos mesmos com a pesquisa. A seguir, no terceiro capítulo, apresentaremos os resultados e análises dos experimentos.

3

MODELOS DE PREDIÇÃO DE SÉRIES TEMPORAIS

ESSE capítulo tem como objetivo apresentar as principais características e formulação matemática dos quatro modelos de predição para os dados de sensoriamento utilizados no experimento da RSSF que foi construída.

3.1 Introdução

Existem várias abordagens diferentes para a previsão de séries temporais, que geralmente são categorizadas da seguinte forma. Os modelos estatísticos lineares tradicionais, incluindo média móvel, suavização exponencial e média móvel integrada auto-regressiva (ARIMA). Estes modelos são lineares porque as previsões dos valores futuros são limitadas a serem funções lineares de observações passadas. E a segunda categoria de modelos, os modelos não lineares. Na literatura, várias classes de modelos não lineares foram propostas para superar a limitação dos modelos lineares, isso inclui o modelo bilinear, o the threshold autoregressive (TAR) model, the autoregressive conditional heteroscedastic (ARCH) model, general autoregressive conditional heteroscedastic (GARCH), chaotic dynamics, and artificial neural networks such as multilayer perceptrons (MLPs), radial basis function networks (RBF), general regression neural networks (GRNNs), support vector machines (SVMs), etc (Khashei & Bijari, 2011) . Nesta seção faremos uma breve descrição dos modelos utilizados no experimento, são eles:

- ARIMA (do inglês, Autoregressive Integrated Moving Average) é um dos mais populares modelos lineares em previsão de séries temporais (Zhang, 2003);
- SVM (do inglês, Support Vector Machines) (Cortes & Vapnik, 1995) é um algoritmo de mineração de dados e considerado um dos métodos mais robustos e precisos entre os conhecidos algoritmos de mineração;

- MLP/ANN (do inglês, Multilayer Perceptron/ Artificial Neural Network) reúne seus conhecimentos detectando padrões e relacionamentos nos dados e aprendendo (ou sendo treinados) através da experiência, não da programação (Zhang et al., 1998).
- LSTM/RNN (do inglês, Long Short-Term Memory/ Recurrent Neural Network) é uma arquitetura de rede neural artificial recorrente (RNN) usada no campo da aprendizagem profunda. Diferente das redes neurais feedforward padrão, o LSTM possui conexões de feedback (Hochreiter & Schmidhuber, 1997).

3.2 Modelos de Predição

3.2.1 Modelo ARIMA

A metodologia de Box-Jenkins (Box & Jenkins, 1976) para a previsão se baseia no ajuste de modelos denominados ARIMA para séries temporais de valores observados. A diferença entre os valores gerados pelos modelos e os valores observados resulta em séries de resíduos de comportamento aleatório em torno de zero. A análise de séries temporais usa os dados históricos para desenvolver um modelo para a previsão de valores. Neste trabalho os dados históricos são os valores coletados pelos nós sensores e enviados para a estação-base, onde é executado um modelo ARIMA para a predição dos dados futuros.

O modelo ARIMA (Liu et al., 2005) é amplamente utilizado para séries temporais univariadas. O mesmo é composto de três termos:

- O termo Auto Regressivo (AR), que é uma regressão linear do valor atual da série contra um ou mais valores anteriores. Ele captura a dependência do valor atual e seus valores anteriores mais próximos;
- O termo de Média Móvel (MA), que é introduzido para capturar a influência de choques aleatórios no futuro, uma vez que geralmente uma série temporal pode receber choques aleatórios em um ambiente ruidoso e pode memorizar os choques recebidos anteriormente por um tempo (Liu et al., 2005);
- O termo Integrador (I) para remover o efeito da não estacionariedade com a diferenciação dos dados, formando assim um modelo ARIMA. Vale destacar que o modelo ARMA, também utilizado, é a combinação dos dois primeiros termos, uma vez que assume que a série é estacionária. No entanto, nem sempre isso acontece, logo o terceiro termo precisa ser introduzido.

O modelo ARMA(p, q) refere-se ao modelo com p termos auto-regressivos e q termos na média móvel. O termo AR(p), de ordem p , pode ser descrito como

$$y_t = c + a_1 y_{t-1} + \dots + a_p y_{t-p} + u_t \quad (3.1)$$

onde a_1, \dots, a_p são parâmetros, c é uma constante, e a variável aleatória u_t é ruído branco. O termo $MA(q)$, de ordem q , pode ser descrito como

$$y_t = \mu + u_t + m_1 u_{t-1} + \dots + m_q u_{t-q} \quad (3.2)$$

onde m_1, \dots, m_q são parâmetros do modelo, μ é a expectativa para y_t (normalmente 0), $u_t, u_{t-1}, \dots, u_{t-q}$ são termos de erro de ruído branco. O modelo contendo os $AR(p)$ e $MA(q)$ pode ser descrito como

$$y_t = c + a_1 y_{t-1} + \dots + a_p y_{t-p} + u_t + m_1 u_{t-1} + \dots + m_q u_{t-q} \quad (3.3)$$

Quando $AR(p)$, $MA(q)$ e $ARMA(p, q)$ são aplicados em alguns casos onde os dados mostram evidência de não-estacionariedade, uma diferenciação inicial deve ser aplicada para reduzir esta não-estacionariedade, chegando-se assim a um modelo ARIMA. Modelos não sazonais são geralmente denotados por $ARIMA(p, d, q)$, onde p é a ordem do modelo AR, d é o grau de diferenciação e q é a ordem do modelo MA (Yuan et al., 2016).

A metodologia de Box–Jenkins inclui três etapas iterativas de identificação de modelo, estimativa de parâmetros e verificação de diagnóstico (Zhang, 2003). A ideia básica da identificação de modelo é que, se uma série temporal for gerada a partir de um processo ARIMA, ela deverá ter algumas propriedades teóricas de autocorrelação. Ao combinar os padrões de autocorrelação empírica com os teóricos, muitas vezes é possível identificar um ou vários modelos potenciais para o tempo determinado. Box e Jenkins (Box & Jenkins, 1976) propuseram usar a função de autocorrelação e a função de autocorrelação parcial dos dados da amostra como ferramentas básicas para identificar a ordem do modelo ARIMA.

Um obstáculo comum para os pesquisadores no uso de modelos ARIMA para previsão é que o processo de seleção de parâmetros geralmente é considerado subjetivo e difícil de aplicar (Hyndman & Khandakar, 2008). Os modelos ARIMA utilizados no algoritmo para realização das previsões das séries temporais dos dados de sensoriamento do experimento montado utilizaram a função **auto.arima** do pacote **forecast** do R. Esta função (**auto.arima**) retorna o melhor modelo ARIMA de acordo com o valor AIC ou BIC (ou SBC) (do inglês, Akaike's 'An Information Criterion e Schwarz's Bayesian criterion, respectivamente). A função realiza uma pesquisa no modelo possível dentro das restrições fornecidas, inclusive testando as funções de autocorrelação e autocorrelação parcial, conforme proposto por Box & Jenkins (1976). No caso específico do experimento montado a única restrição foi a ordem do modelo (parâmetros p e q) serem no máximo igual 30.

Segue abaixo trecho do código utilizado para a criação dos modelos ARIMA na RSSF.

```

1 data <- temperatures
2 fit <- auto.arima(data, max.p = 30, max.q = 30)
3 fcast <- forecast(fit, h=30)
4 fcast <- fcast$mean

```

3.2.2 Modelo SVM

As máquinas de vetor de suporte (SVMs) implementam o princípio da minimização de risco estruturada (SRM, do inglês, Structured Risk Minimization) em vez do princípio de minimização de risco empírico implementado pela maioria dos tradicionais modelos de rede neural. O conceito mais importante de SRM é a minimização de um limite superior para o erro de generalização em vez de minimizar o erro de treinamento. Com base nesse princípio, as SVMs conseguem uma ótima estrutura de redes (Pai & Hong, 2005).

Os modelos SVMs geram a função de regressão aplicando um conjunto de funções lineares de altas dimensões. A função de regressão SVM é formulada da seguinte forma (Pai & Lin, 2005)

$$y = w\phi(x) + b \quad (3.4)$$

onde $\phi(x)$ é chamado de recurso (*feature* em inglês), que é oriunda do mapeamento não linear do espaço de entrada de x . Os coeficientes w e b são estimados pela minimização

$$R(C) = C \frac{1}{N} \sum_{i=1}^N L_{\varepsilon}(d_i, y_i) + \frac{1}{2} \|w\|^2 \quad (3.5)$$

onde

$$L_{\varepsilon}(d, y) = \begin{cases} |d - y| - \varepsilon & |d - y| \geq \varepsilon \\ 0 & \text{outros} \end{cases} \quad (3.6)$$

C e ε são parâmetros prescritos. O primeiro termo $L_{\varepsilon}(d, y)$ é chamado de função de perda ε -itensiva. O d_i é o valor atual da série no período de índice i . Esta função indica que o erro abaixo ε não é penalizado. O termo $C \frac{1}{N} \sum_{i=1}^N L_{\varepsilon}(d_i, y_i)$ é o erro empírico. O segundo termo, $\frac{1}{2} \|w\|^2$ mede a planicidade da função. C avalia o *trade-off* entre o risco empírico e a planicidade do modelo. Introduzindo as variáveis de folga positivas ζ e ζ^* , que representam as distâncias dos valores reais para os valores limites de ε -tubo. A equação 3.5 é transformada na seguinte forma

Minimizar:

$$R(w, \zeta, \zeta^*) = \frac{1}{2} w w^T + C^* \left(\sum_{i=1}^N (\zeta_i + \zeta_i^*) \right) \quad (3.7)$$

Sujeito a:

$$w\phi(x_i) + b_i - d_i \leq \varepsilon + \zeta_i^* \quad (3.8)$$

$$d_i - w\phi(x_i) - b_i - d_i \leq \varepsilon + \zeta_i \quad (3.9)$$

$$\zeta_i, \zeta_i^* \geq 0 \quad (3.10)$$

com $i = 1, 2, \dots, N$. Introduzindo o multiplicador de Lagrange e maximizando a função dupla da Equação 3.7, temos

$$\begin{aligned} R(\alpha_i - \alpha_i^*) &= \sum_{i=1}^N d_i (\alpha_i - \alpha_i^*) - \varepsilon \sum_{i=1}^N (\alpha_i - \alpha_i^*) - \\ &\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N (\alpha_i - \alpha_i^*) \times (\alpha_j - \alpha_j^*) K(x_i, x_j) \end{aligned} \quad (3.11)$$

com as restrições

$$\sum_{i=1}^N (\alpha_i - \alpha_i^*) = 0 \quad (3.12)$$

sendo $0 \leq \alpha_i \leq C$ e $0 \leq \alpha_i^* \leq C$ com $i = 1, 2, \dots, N$. Na Equação 3.11, α_i e α_i^* são chamados de multiplicadores de Lagrange (Pai & Lin, 2005). Eles satisfazem as igualdades

$$\alpha_i * \alpha_i^* = 0, \quad (3.13)$$

$$f(x, \alpha, \alpha^*) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) K(x_i, x_j) + b \quad (3.14)$$

onde $K(x, x_i)$ é a função Kernel. O valor da Kernel é igual ao produto interno dos vetores x_i e x_j no espaço do recurso $\phi(x_i)$ e $\phi(x_j)$, de modo que $K(x_i, x_j) = \phi(x_i) * \phi(x_j)$. Qualquer função que satisfaça a condição de Mercer pode ser usada como função Kernel (Pai & Lin, 2005). A condição Mercer é a regra para determinar uma Kernel admissível de vetor de suporte (Xiao-Ying et al., 2009). Neste estudo utilizamos função Kernel do tipo radial.

Segue abaixo trecho do código utilizado para a criação dos modelos SVM na RSSF.

```

1 data <- temperatures
2 x <- 1:length(data)
3 dataFrame <- data.frame(x, data)
4 svm_model <- tune(svm, data ~ x, data = dataFrame,
5 ranges = list(epsilon = seq(0,1,0.1), cost = 2^(2:5))
6 svm_model <- svm_model$best.model
7 from <- length(data)
8 to <- 2*from - 1
9 fcast <- predict(svm_model, newdata = data.frame(x = from:to)

```

3.2.3 Modelo MLP/ANN

As redes neurais artificiais (ANN) podem modelar uma ampla gama de problemas não-lineares (Wong et al., 2000). Uma vantagem significativa dos modelos de ANN em relação às de outras classes de modelos não lineares é que eles são aproximadores universais que podem aproximar uma grande quantidade de funções com um alto grau de precisão (Chen et al., 2003). A rede Feed Forward de camada simples é a forma mais amplamente usada para modelagem e previsão de séries temporais (Khashei et al., 2008). O modelo é caracterizado por uma rede de três camadas de unidades de processamento simples, conectadas por elos acíclicos (Figura 3.1, (Khashei et al., 2012)).




Figura 3.1: Estrutura de Rede Neural. Figura retirada de (Khashei et al., 2012).

A relação entre a saída (y_t) e as entradas (y_{t-1}, \dots, y_{t-n}) tem a seguinte representação matemática (Khashei et al., 2012):

$$y_t = \omega_0 + \sum_{j=1}^m \omega_j g\left(\omega_{0,j} + \sum_{i=1}^n \omega_{i,j} y_{t-i}\right) + e_t, \quad (3.15)$$

onde $\omega_{i,j}$ ($i = 0, 1, 2, \dots, n; j = 1, 2, \dots, m$) e ω_j ($j = 0, 1, 2, \dots, m$) são os parâmetros do modelo geralmente chamados de pesos de conexão; P é o número de nós de entrada; e m é o número de nós ocultos. A função logística é frequentemente usada como a função de transferência de camada oculta, ou seja,

$$\text{Sig}(x) = \frac{1}{1 + \exp(-x)} \quad (3.16)$$

Portanto, o modelo ANN de 3.15, (Khashei et al., 2012), de fato, executa um mapeamento funcional não linear das observações passadas para o valor futuro y_t , ou seja,

$$y_t = f(y_{t-1}, \dots, y_{t-n}, W) + e_t, \quad (3.17)$$

onde W é um vetor de todos os parâmetros e f é uma função determinada pela estrutura da rede e pelos pesos da conexão. Desta forma, a rede neural é equivalente a um modelo autorregressivo não linear. A expressão 3.15 implica um nó de saída na camada de saída, que é normalmente usado para previsão um passo à frente. A rede dada por 3.15 é capaz de aproximar funções arbitrárias, pois o número de nós ocultos m é suficientemente grande (Zhang et al., 1998). Na prática, uma estrutura de rede simples que possui um pequeno número de nós ocultos geralmente funciona bem na previsão e isso pode ser devido ao efeito de ajuste excessivo normalmente encontrado no processo de modelagem de redes neurais. Ocorre quando a rede possui muitos parâmetros livres, o que permite que a rede ajuste bem os dados de treinamento, mas geralmente leva a uma generalização ruim (Khashei et al., 2012).

A escolha de m depende dos dados e não há regra sistemática para decidir esse parâmetro. Além disso, escolhendo um número apropriado de nós ocultos, outra tarefa importante da modelagem de redes neurais artificiais de uma série temporal é a seleção do número de observações n e a dimensão do vetor de entrada (Thawornwong & Enke, 2004). Esse talvez seja o parâmetro mais importante a ser estimado em um modelo ANN, pois desempenha um papel importante na determinação da estrutura de autocorrelação (não-linear) da série temporal. No entanto, não existe uma teoria que possa ser usada para orientar a seleção de n . Portanto, experimentos são frequentemente realizados para selecionar um n e um m apropriados (Khashei et al., 2012).

Várias abordagens diferentes, como o algoritmo de poda, o algoritmo de tempo polinomial, a técnica de decomposição canônica e o critério de informações de rede, foram propostas

para encontrar a arquitetura ideal de uma rede neural (Khashei et al. 2005). Essas abordagens geralmente podem ser categorizadas da seguinte maneira (Khashei et al., 2012):

- Métodos empíricos ou estatísticos usados para estudar o efeito de parâmetros de redes neurais e escolher valores apropriados para eles com base no desempenho do modelo (Benardos & Vosniakos, 2007);
- Métodos híbridos, como inferência difusa (Leski & Czogala, 1999), onde a ANN pode ser interpretada como um sistema difuso adaptativo ou nos casos em que pode operar com números difusos em vez de números reais;
- Algoritmos construtivos e/ou de poda que, respectivamente, adicionam e/ou removem neurônios de uma arquitetura inicial usando um critério especificado anteriormente para indicar como o desempenho da ANN é afetado pelas mudanças (Jiang & Wah, 2003).
- Estratégias evolutivas que pesquisam no espaço da topologia variando o número de camadas ocultas e neurônios ocultos através da aplicação de operadores genéticos e avaliação das diferentes arquiteturas de acordo com uma função objetivo (Benardos & Vosniakos, 2007).

As regras básicas são que os neurônios são adicionados quando o treinamento é lento ou quando o erro quadrado médio é maior que um valor especificado e que os neurônios são removidos quando uma alteração no valor de um neurônio não corresponde a uma alteração na resposta da rede ou quando o peso os valores associados a esse neurônio permanecem constantes por um grande número de épocas de treinamento (Perez-Marin et al., 2007).

Embora muitas abordagens diferentes tenham sido propostas para encontrar a arquitetura ideal de uma RNA, esses métodos geralmente são de natureza bastante complexa e difíceis de implementar (Zhang et al., 1998).

O tipo de rede neural utilizada neste trabalho foi a multi-layer perceptrons (MLP). As redes MLP são usadas na predição devido a sua capacidade de mapeamento arbitrário de entrada e saída. Uma rede MLP é tipicamente composta por várias camadas. A primeira camada serve como entrada e a última é uma camada de saída onde a solução do problema é obtida. A camada de entrada e a camada de saída são separadas por uma ou mais camadas intermediárias, chamadas camadas ocultas. Os elementos das camadas adjacentes (neurônios artificiais ou nós) são totalmente conectados por arcos acíclicos de uma camada inferior a uma camada superior. A Figura 3.2 dá um exemplo de um MLP totalmente conectado com uma camada oculta (Zhang et al., 1998).

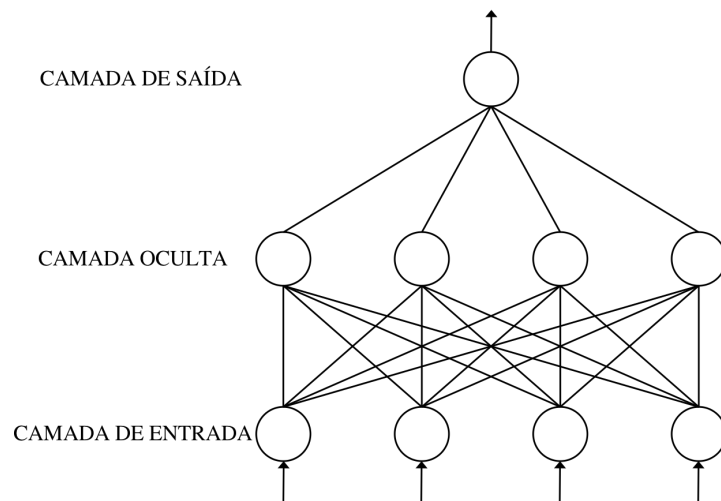


Figura 3.2: Uma típica rede neural feedforward

Para o problema de predição, as entradas são geralmente as variáveis independentes ou predictoras. A relação funcional estimada pela ANN pode ser escrita como

$$y = f(x_1, x_2, \dots, x_p) \quad (3.18)$$

onde x_1, x_2, \dots, x_p são as p variáveis independentes e y é a variável dependente. Nesse sentido, a rede neural é funcionalmente equivalente a um modelo de regressão não linear. Para um problema de predição de séries temporais, as entradas são tipicamente as observações passadas e a saída é o valor futuro. A ANN executa o seguinte mapeamento de funções

$$y_{t+1} = f(y_t, y_{t-1}, \dots, y_{t-p}) \quad (3.19)$$

onde y_t é a observação no tempo t . Assim, o modelo ANN é equivalente ao modelo autorregressivo não linear para problemas de predição de séries temporais.

O modelo ANN necessita ser treinado antes de realizar a tarefa desejada. O treinamento é o processo de determinar os parâmetros do modelo (geralmente ajuste dos pesos) e ele pode ocorrer de forma supervisionada ou não supervisionada. Para o problema de predição em séries temporais, um padrão de treinamento consiste em um número fixo de observações defasadas da série. Ou seja, suponha que temos N observações y_1, y_2, \dots, y_N no conjunto de treinamento e precisamos da predição em um passo à frente. Usando um modelo ANN com n nós de entrada, temos $N - n$ padrões de treinamento. O primeiro padrão de treinamento será composto de y_1, y_2, \dots, y_n como entradas e y_{n+1} como a saída alvo. O segundo padrão de treinamento conterá y_2, y_3, \dots, y_{n+1} como entradas e y_{n+2} como a saída desejada. Finalmente, o último padrão de treinamento será $y_{N-n}, y_{N-n+1}, \dots, y_{N-1}$ para entradas e y_N para o alvo. Comumente uma função objetivo utilizada durante o processo de treinamento é dada por

$$E = \frac{1}{2} \sum_{i=n+1}^N (y_i - \alpha_i)^2 \quad (3.20)$$

onde α_i é a saída real da rede e o valor 1/2 é o fator de simplificação da expressão de derivadas computadas no algoritmo de treinamento.

Segue abaixo trecho do código utilizado para a criação dos modelos MLP/ANN na RSSF.

```
1 temperatures <- temps
2 data <- ts(temperatures)
3 ann_fit <- nnetar(data, p=6, P=1, decay=0.01, repeats=10)
4 fcast <- forecast(ann_fit, 30)
5 fcast <- fcast$mean
```

3.2.4 Modelo LSTM/ANN

LSTM/RNN (do inglês, Long Short-Term Memory/ Recurrent Neural Network), é uma variação das redes neurais recorrentes (Hochreiter & Schmidhuber, 1997) para permitir a preservação dos pesos que são propagados para frente e para trás através de camadas. RNNs baseados em LSTM são uma opção atraente para modelar dados sequenciais como séries temporais, pois incorporam informações contextuais de entradas anteriores. A técnica para previsão de séries temporais ganhou popularidade devido à sua modelagem de ponta a ponta, aprendendo padrões não lineares complexos e habilidades de extração automática de recursos (Bouktif et al., 2018).

Uma rede neural recorrente é aquela que aprende padrões sequenciais através de loops internos ao receber sequências de entrada. A retro propagação é realizada para aprender os pesos, e o *slope* (inclinação) calculado pela regra da cadeia. Como os valores são retro propagados para a função de ativação, como as funções sigmóides e *tanh*, a inclinação se torna extremamente pequena (ou extremamente grande) e encontra o problema de desaparecer. A retro propagação é vulnerável à dependência de longo alcance. Modelos LSTM foram desenvolvidos para evitar esses problemas. (Hochreiter & Schmidhuber, 1997) introduziram LSTMs que usavam recursos de memória para armazenar informações por longos períodos de tempo ou para esquecer informações desnecessárias (Kim & Won, 2018).

$$g_t = \sigma(U_g x_t + W_g h_{t-1} + b_f) \tag{3.21}$$

$$i_t = \sigma(U_i x_t + W_i h_{t-1} + b_i) \tag{3.22}$$

$$\tilde{c}_t = \tanh(U_c X_t + W_c h_{t-1} + b_c) \tag{3.23}$$

$$c_t = g_t * c_{t-1} + i_t * \tilde{c}_t \tag{3.24}$$

$$o_t = \sigma(U_o X_t + W_o h_{t-1} + b_o) \tag{3.25}$$

$$h_t = o_t * \tanh(c_t) \tag{3.26}$$

LSTMs são compostos de blocos de memória em vez de neurônios. Como pode ser visto na Figura 3.3, o LSTM é composto por uma célula de memória (c_t) e três portas: uma porta "Input Gate" (i_t), uma porta "Forget Gate" (g_t) e uma porta "Output Gate" (o_t). No momento t , x_t representa a entrada e h_t o estado oculto. O símbolo \otimes denota a multiplicação pontual. \tilde{c} , também chamado de entrada modular, é um valor que determina quanta informação nova é recebida no estado da célula. As três portas, a célula de memória (c_t) e o estado oculto h_t são calculados conforme mostrado nas Equações 3.21-3.26. Nestas equações, U e W são matrizes de peso, b é um termo de viés, $\sigma(\cdot)$ é uma função sigmoide e o símbolo $*$ indica multiplicação por elementos (Kim & Won, 2018).




Figura 3.3: Uma típica rede de blocos de memória LSTM. Figura retirada de (Kim & Won, 2018).

Primeiro, a "Forget Gate" g_t da 3.21 produz a soma ponderada de x_t , h_{t-1} e viés como um valor de 0 a 1 através da função sigmoide. Um valor de 1 significa que todas as informações de entrada passam pelo porta e um valor de 0 significa que nenhuma informação de entrada é passada. Portanto, a "Forget Gate" controla a quantidade de informações no estado anterior da célula (c_{t-1}) na atualização do estado da célula no tempo t , conforme mostrado na 3.24. 3.22 é a fórmula de cálculo da entrada e determina a quantidade de informações novas

armazenadas no estado da célula (c_t). 3.23 calcula as novas informações no tempo t e sua saída através da função \tanh tem um valor entre -1 e 1. As informações passadas do estado da célula e as novas informações, que são controladas pelas "Forget Gate" e de "Input Gate", são calculadas como a variável c_t de tempo t , conforme observado na 3.24. Finalmente, o valor de saída h_t é determinado passando pela "Output Gate" o_t 3.23 e filtrando em c_t , enquanto c_t passa para a função \tanh , de modo que o valor esteja entre -1 e 1. Os valores selecionados são convertidos para saída multiplicando-os por o_t . Esse processo atualiza o estado da célula c_{t-1} , as informações necessárias são separadas das informações desnecessárias e a saída se torna h_t , conforme observado na 3.26. O modelo LSTM que consiste nesses blocos de memória é treinado usando a retro propagação por meio do algoritmo de tempo (Kim & Won, 2018).

Segue abaixo trecho do código utilizado para a criação dos modelos LSTM/ANN na RSSF.

```

1 model <- keras_model_sequential()
2 model %>%
3     layer_lstm(1, batch_input_shape = c(1, 1L, 1L),
4         stateful= TRUE) %>%
5     layer_dense(units = 1)
6 model %>% compile(loss = 'mean_squared_error',
7     optimizer = optimizer_adam( lr= 0.02, decay = 1e-6 ),
8     metrics = c('accuracy'))
9 size <- length(temperatures)
10 predictions = numeric(size)
11 for(i in 1:size) {
12 X = temperatures[i]
13 dim(X) = c(1,1,1)
14 yhat = model %>% predict(X, batch_size=1)
15 predictions[i] <- yhat

```

O presente capítulo tratou da formulação matemática e da apresentação dos modelos utilizados nos algoritmos implementados nos dispositivos da RSSF. A seguir, é apresentada a aplicação e os resultados obtidos na comparação dos modelos.

4

RESULTADOS

ESSE capítulo apresenta a aplicação desenvolvida, as avaliações realizadas nas coletas de dados e os resultados da comparação entre os modelos de predição de dados de sensoriamento na RSSE.

4.1 Aplicação

Com o objetivo de aplicar técnicas de predição de séries temporais para redução de dados de uma RSSE, foi desenvolvida uma aplicação real utilizando dispositivos de baixo custo. O experimento, RSSE, destinado para coleta de dados de temperatura, foi composto por 5 dispositivos da plataforma MICAz¹, sendo 4 destes dispositivos utilizados como nós (sensores) e 1 como estação-base. A estação-base foi conectada a um computador de mesa que atuou como *gateway*. No *gateway* é feito processamento de dados e nele são executados os modelos ARIMA, SVM, MLP/ANN e LSTM/RNN. Os nós foram colocados próximos um do outro para mensurar simultaneamente sob as mesmas condições do ambiente e o distanciamento de cada nó para a estação-base é de aproximadamente 5 centímetros. Um diagrama da aplicação é apresentado na Figura 4.1, onde é observada a relação entre nó, estação-base e o *gateway*. Este experimento foi um caso teste para a aplicação da metodologia, uma vez que o ambiente de escritório permite outros métodos de controle de temperatura.

Cada dispositivo foi programado conforme seu papel na RSSE, sendo que, os nós sensores mensuram e transmitem dados de temperatura diretamente para a estação-base, que por sua vez os recebe e os transmite para o *gateway*. Ao receber os dados, o *gateway* processa e gera um conjunto de predições para um dos modelos citados, isto é, um conjunto de predições para o ARIMA, SVM, MLP/ANN ou LSTM/RNN, a depender do nó que realizou a transmissão.

¹http://www.memsic.com/userfiles/files/Datasheets/WSN/micaz_datasheet-t.pdf, acessado em março de 2018

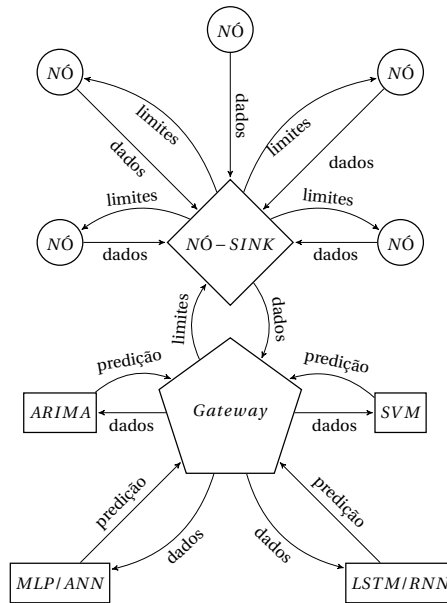


Figura 4.1: RSSF - Diagrama de aplicação.

Cada conjunto de previsões possui 30 valores gerados a partir das 30 últimas temperaturas transmitidas e, com os valores preditos, calcula-se uma média. Com a média, são definidos limites superiores e inferiores que serão utilizados como parâmetros para determinar quando um nó deve ou não transmitir um pacote de dados. O limite superior é dado pela soma de um valor δ à média de um conjunto de previsões e, de maneira análoga, o limite inferior é dado pela subtração deste valor da média. O *gateway* é responsável por calcular estes limites e transmiti-los para para um determinado nó da rede através da estação-base.

Cada nó mensura e armazena localmente dados de temperatura de segundo em segundo e, ao final de 30 segundos, os transmite para a estação-base, caso os limites calculados pelo *gateway* tenham sido ultrapassados. Para fins de comparação, as transmissões foram feitas de forma contínua (o nó sempre transmitindo a cada 30 segundos) e intermitente (transmite às vezes). Dos quatro nós sensores utilizados, além da estação-base, um destes realizou transmissão continuamente e os outros quatro transmitiram apenas no caso de ultrapassagem dos limites superiores ou inferiores, sendo que, um nó teve seus limites definidos com base nas previsões do ARIMA, um nas previsões do SVM, um nas previsões do MLP/ANN e o quarto baseado em previsões do LSTM/RNN. Caso um nó ultrapasse seu limite superior ou inferior, um pacote de medições é transmitido, e o *gateway* calcula novos limites e os transmite para o nó.

O *gateway* mantém versões virtuais dos nós físicos da rede, ambos funcionam em sincronia de modo que, sempre que um nó físico não realizar uma transmissão, o *gateway* assumirá que os valores das medições estão dentro dos limites calculados e o nó virtual armazenará um conjunto de temperaturas preditas por seu respectivo algoritmo. Este conjunto de temperaturas será armazenado repetidamente até que um novo pacote de dados seja recebido e

novas predições sejam realizadas. Nesta situação, os valores reais de temperatura recebidos serão armazenados e, passados 30 segundos, se um novo pacote não for recebido, o nó virtual armazenará periodicamente valores de predição baseados nos valores reais.

A curva final de temperatura de um nó é portanto constituída de valores reais e preditos, como observado na Figura 4.2. Os trechos pontilhados do gráfico da Figura 4.2 caracterizam os momentos em que não houve transmissão, ou seja, são valores preditos. É esperado que com um número reduzido de envio de pacotes os nós consumam menos energia. Todos os nós estão executando a mesma aplicação. O nó que está sempre transmitindo não recebe resposta alguma do *gateway* e logo não possui limites definidos.

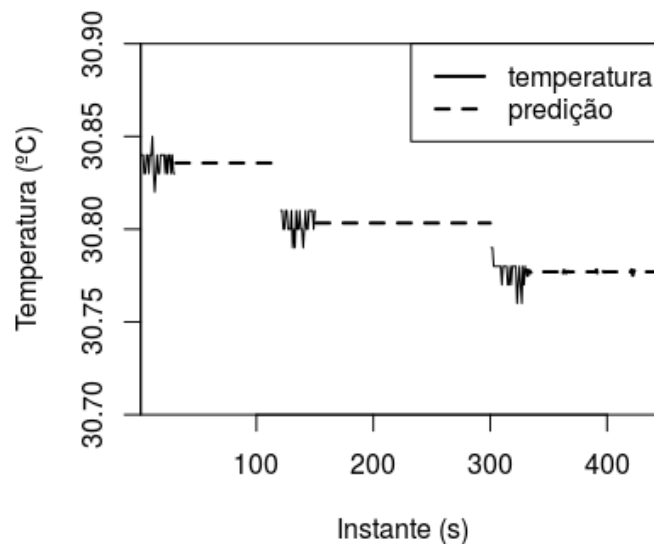


Figura 4.2: Gráfico de temperaturas reais e preditas

4.2 Acurácia dos Modelos

Foram realizadas 4 (quatro) coletas de temperatura durante os meses de agosto a outubro do ano 2019 em um laboratório da Universidade Federal de Alagoas. Cada uma destas coletas utilizou um valor de δ e durações diferentes. Foram utilizadas neste trabalho 691.200 medições de temperatura em cada um dos nós sensores da RSSF, totalizando aproximadamente 3,5 milhões de medições de temperatura, reais e preditas. Na Tabela 4.1 é apresentado um resumo dos parâmetros de cada uma das coletas.

A acurácia dos modelos de predição foi medida comparando a curva real da temperatura com a curva construída a partir das predições de cada um dos modelos. Para esta avaliação foi utilizado o MAPE (do inglês, Mean Absolute Percentage Error) como determinado pela

	COLETA 1	COLETA 2	COLETA 3	COLETA 4
δ	0,2	0,3	0,5	0,7
Duração	24h	24h	96h	48h

Tabela 4.1: Coletas realizadas na RSSF

Equação 4.1.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{d_i - y_i}{d_i} \right| \cdot 100\% \quad (4.1)$$

Quando os modelos de predição precisam ser comparados em diferentes séries temporais, medidas de acurácia como MSE (do inglês, Mean Squared Error) e o MAE (do inglês, Mean Absolute Error) são inadequadas (Goodwin & Lawton, 1999). Isso pode ocorrer porque grandes variações na escala das observações entre as séries podem acarretar que séries com grandes valores possam dominar as comparações. Nessas circunstâncias, medidas livres de unidades, como o MAPE, são indicadas (Goodwin & Lawton, 1999). O MAPE (Em português, Média Percentual Absoluta do Erro) expressa a acurácia do erro em porcentagem, ou seja, expressa quantos por cento dos dados não estão ajustados à série temporal real. Quanto menor o MAPE, melhor.

Foi avaliado a acurácia dos modelos comparando a curva real de temperatura com a curva oriunda de cada um dos modelos para as quatro coletas e considerando intervalos de tempo diferentes. Nas Figuras 4.3 e 4.4 podemos ver exemplos das coletas número 2 e 4, com durações de 12 horas e δ iguais a 0,3 e 0,7, respectivamente. O resultado das avaliações de erro de cada um dos modelos de predição para os dados de sensoriamento da RSSF pode ser visto na Tabela 4.2. A curva preta representa a série temporal real das temperaturas, oriunda do nó sensor que mede e sempre envia os valores sensorizados. As curvas coloridas nas cores azul, vermelha, verde e roxa, representam as séries temporais formadas por trechos de temperaturas reais e preditas, de acordo com o nó sensor e seu modelo, ARIMA, SVM, MLP/ANN e LSTM/RNN, respectivamente, conforme apresentado na Figura 4.2.

Em todos os cenários de δ e duração da coleta analisados o MAPE para o modelo SVM apresentou valores inferiores aos demais, sendo assim, o modelo com maior acurácia na predição da curva de temperatura real. O modelo LSTM/RNN apresentou os maiores valores de erro percentual.

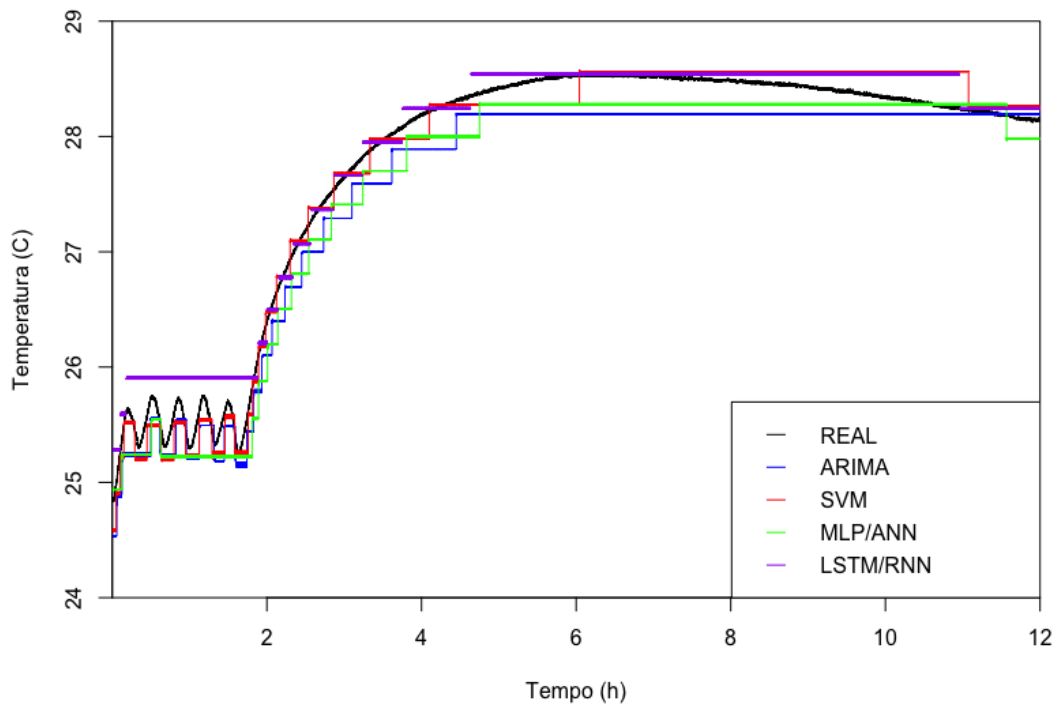


Figura 4.3: Temperatura real e predições. Coleta 2, 12 horas de amostras e $\delta = 0,3$.

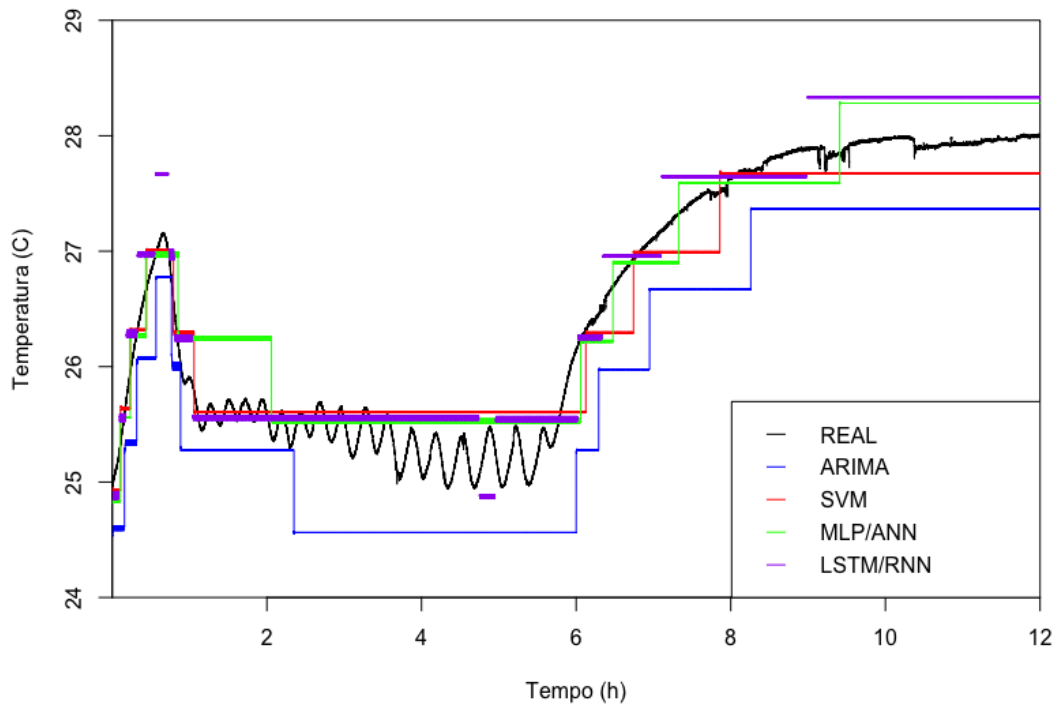


Figura 4.4: Temperatura real e predições. Coleta 4, 12 horas de amostras e $\delta = 0,7$.

	ARIMA	SVM	MPL/ANN	LSTM/RNN
COLETA 1 ($\delta = 0,2$)				
6h	1,277%	1,083%	0,983%	5,126%
12h	1,617%	1,115%	0,895%	3,226%
18h	1,543%	0,896%	0,782%	2,805%
24h	1,531%	1,012%	0,897%	3,111%
COLETA 2 ($\delta = 0,3$)				
6h	0,939%	0,462%	0,954%	0,228%
12h	0,834%	0,454%	0,743%	0,138%
18h	0,702%	0,504%	0,744%	0,186%
24h	0,756%	0,595%	0,958%	0,240%
COLETA 3 ($\delta = 0,5$)				
6h	1,067%	0,679%	1,688%	4,012%
12h	1,192%	0,841%	1,658%	3,462%
18h	1,661%	0,945%	1,436%	3,214%
24h	1,630%	0,831%	1,482%	2,648%
48h	1,626%	0,931%	1,527%	2,646%
96h	1,914%	1,229%	1,710%	2,668%
COLETA 4 ($\delta = 0,7$)				
6h	2,467%	0,928%	1,181%	2,319%
12h	2,417%	0,921%	1,053%	1,946%
18h	2,370%	0,999%	1,037%	1,694%
24h	2,477%	0,984%	0,921%	1,547%
48h	1,939%	1,130%	1,345%	1,820%

Tabela 4.2: MAPE (Mean Absolute Percentage Error).

4.3 Número de Transmissões Evitadas

Uma outra forma de avaliar a qualidade dos modelos é quantificando o número de transmissões evitadas em virtude da predição dos valores da série temporal. Este envio suprimido e substituído por um valor predito vai impactar diretamente na eficiência energética da RSSF, uma vez que as transmissões são uma parcela relativamente grande do consumo do nó sensor. No caso do experimento de RSSF realizado os valores de transmissões evitadas ficaram maiores nos modelos ARIMA e SVM, ficando entre 96% a 99%. E ficaram entre 88% a 89% nos modelos MLP/ANN e LSTM/RNN, conforme pode ser visto na Tabela 4.3. Porém, como é esperado, nota-se um aumento do percentual de transmissões evitadas com o aumento do parâmetro δ em todos os modelos.

	ARIMA	SVM	MPL/ANN	LSTM/RNN
COLETA 1 ($\delta = 0,2$)	97,99%	98,02%	88,19%	88,68%
COLETA 2 ($\delta = 0,3$)	97,50%	96,56%	86,94%	88,22%
COLETA 3 ($\delta = 0,5$)	99,44%	98,28%	89,14%	88,75%
COLETA 4 ($\delta = 0,7$)	99,67%	99,69%	89,69%	89,62%

Tabela 4.3: Percentual de redução de transmissões.

4.4 Eficiência Energética

Para comparar o desempenho dos modelos quanto à eficiência energética durante o fornecimento de potência elétrica das baterias para os nós sensores, foram coletados os dados relativos ao descarregamento destas baterias no período das coletas. O descarregamento destas baterias pode ser graficamente visualizado através de uma curva onde temos no eixo x a variável tempo e no eixo y a variável tensão elétrica. Durante o ciclo de funcionamento, a tensão elétrica decai de forma suave até valores toleráveis pela aplicação, e então, diminui abruptamente fazendo com que o sistema não opere mais, devido ao fato de estar com o nível de tensão inadequado. Esta curva pode ser chamada de curva de descarregamento das baterias. Na Figura 4.5, temos a amostra da coleta 4, de 24h, onde podemos ver parte do decaimento da tensão das baterias em cada um dos cinco nós durante o sensoriamento da temperatura. Na Figura 4.6, são apresentadas as curvas de Potência Entregue em cada um dos nós. A curva de Potência Entregue é proporcional ao quociente do quadrado da tensão pela resistência do circuito e resistência interna das baterias.




Figura 4.5: Curva de Descarga das Baterias. Coleta 4, 24 horas de amostras e $\delta = 0,7$

Para a avaliação da eficiência energética dos modelos de previsão do sensoriamento da temperatura foi verificada a quantidade de energia, correspondente às diferenças das áreas sob as curvas, conforme exemplo do gráfico da Figura 4.6, de cada um dos modelos em relação ao nó que sempre envia seus dados, desta forma, verificando quanto a supressão do envio




Figura 4.6: Curva de Potência Entregue. Coleta 4, 24 horas de amostras e $\delta = 0,7$

de dados trouxe de economia de energia para as baterias. Na Tabela 4.4 são apresentados os valores de economia de energia para cada um dos modelos nas diversas durações de coletas e valores de δ .

As baterias que se encontravam no nó sensor relativo ao modelo SVM apresentaram uma maior economia quando comparado com os demais. Conforme pode ser visto na Tabela 4.4, economias de até 10% na Coleta 4. Os modelos MLP/ANN e RNN/LSTM apresentaram valores de economia de energia inferiores. A eficiência energética está diretamente relacionada com a acurácia do modelo, pois uma vez que o modelo fornece valores de limites (δ) que são ultrapassados pelas temperaturas reais sensoriadas, este nó envia os dados para a estação base, ativando assim o sistema de transmissão do dispositivo e conseqüentemente gastando energia elétrica das baterias.

4.5 Tempo de Execução

Na Tabela 4.5 temos os tempos de execução no *gateway*, em milissegundos, dos modelos em cada um dos momentos que foi necessário recalculas as predições para definição dos limites do algoritmo da aplicação. Nenhum tempo de execução ultrapassou o tempo de 30 segundos, que corresponde ao espaço de tempo onde o nó sensor pode ter enviado as últimas

	ARIMA	SVM	MPL/ANN	LSTM/RNN
COLETA 1 ($\delta = 0,2$)				
6h	2,3%	3,1%	0,3%	3,7%
12h	2,1%	3,0%	-0,2%	4,0%
18h	3,4%	3,7%	-4,0%	5,4%
24h	3,8%	4,6%	-4,6%	5,9%
COLETA 2 ($\delta = 0,3$)				
6h	0,8%	0,9%	2,4%	1,3%
12h	3,2%	2,0%	4,2%	1,7%
18h	2,9%	1,8%	3,6%	0,8%
24h	2,1%	1,5%	1,5%	0,0%
COLETA 3 ($\delta = 0,5$)				
6h	1,0%	0,9%	-1,3%	0,9%
12h	0,8%	1,0%	-1,9%	0,8%
18h	0,7%	0,9%	-2,3%	-0,2%
24h	1,1%	1,4%	-2,2%	-0,2%
48h	1,5%	1,4%	-2,2%	-5,4%
96h	1,2%	1,8%	-2,3%	-6,0%
COLETA 4 ($\delta = 0,7$)				
6h	7,1%	10,0%	6,9%	7,8%
12h	8,3%	10,4%	5,6%	8,8%
18h	8,1%	9,8%	4,2%	8,2%
24h	6,9%	8,0%	2,8%	6,9%
48h	5,7%	6,6%	1,5%	5,6%

Tabela 4.4: Eficiência Energética dos Modelos

30 medições (uma por segundo) de temperatura para o cálculo de novos limites. Vale ressaltar que os modelos ARIMA e SVM apresentaram valores inferiores aos modelos MLP/ANN e LSTM/RNN. Os modelos baseados em redes neurais demonstraram que demandam um tempo maior para executar os cálculos. Como a execução do modelo ocorre no *gateway* não há como traçar uma correlação direta entre o tempo de execução e a eficiência energética nos nós sensores, porém é uma indicação do esforço computacional que o sensor pode necessitar quando a aplicação e execução dos modelos sejam realizados no próprio nó.

A aplicação consiste em uma RSSF com nós sensores que enviam seus dados de temperatura quando estes ultrapassam limites estabelecidos a partir de modelos de predição que são executados no *gateway*. Para a análise realizada neste trabalho 4 coletas foram realizadas com parâmetros e durações diferentes que mostraram que o modelo baseado em SVM tem uma acurácia maior em relação aos demais, sendo acompanhado nesta análise pelo modelo MLP/ANN e ARIMA. Em relação ao número de transmissões os modelos ARIMA e SVM tiveram vantagem em relação aos demais, com cerca de 10% a mais de economia de transmissão de pacotes (dados). Do ponto de vista de eficiência energética o nó sensor com o modelo SVM também apresentou os maiores percentuais de economia de energia, e, mesmo não havendo como correlacionar diretamente, os tempos de execução do modelo SVM também foram os menores, acompanhados de perto pelos tempos de execução do modelo ARIMA. Na Tabela 4.6 temos um resumo dos resultados, mostrando os modelos do melhor para o pior

	ARIMA	SVM	MPL/ANN	LSTM/RNN
COLETA 4 ($\delta = 0,7$)	62	41	1163	4989
	77	39	1097	3367
	74	40	1119	3404
	10	39	1119	3452
	50	39	1111	3458
	73	40	1122	3384
	55	42	1214	3389
	11	42	1124	3350
	60	39	1228	3431
	46	41	1167	3386
	47	43	1159	3453
	11	40	1135	3411
	39	39	291	3390
	42	38	1262	3369
	65	40	1207	3424
	84	41	1129	3484
	42	42	1279	3390
	38	42	1135	3401
	54	43	1186	5763

Tabela 4.5: Tempo de execução dos modelos em milisegundos

dentro das análises dos cenários de coletadas da RSSF montada para este trabalho.

	MELHOR	->	->	PIOR
ACURÁCIA DO MODELO	SVM	MLP/ANN	ARIMA	LSTM/RNN
TRANSMISSÕES EVITADAS.	SVM	ARIMA	LSTM/RNN	MLP/ANN.
EFICIÊNCIA ENERGÉTICA	SVM	ARIMA	LSTM/RNN	MLP/ANN
TEMPO DE EXECUÇÃO	SVM	ARIMA	MLP/ANN	LSTM/RNN

Tabela 4.6: Comparativo dos Modelos.

O presente capítulo apresentou os resultados de quatro coletas de dados para cada um dos modelos avaliados. Mais de 3,5 milhões de dados de temperatura que foram responsáveis por apresentar as situações onde um ou outro modelo se destaca.

5

CONCLUSÕES

NESTE capítulo apresentaremos as considerações finais para a comparação entre os modelos de predição aplicados em séries temporais relativas a dados de sensoriamento em RSSF e propostas de trabalhos futuros.

5.1 Considerações Finais

A eficiência energética em redes de sensores sem fio é motivo de ampla pesquisa e apresenta diversas abordagens que podem ser agrupadas em classes conforme mostrado nesta dissertação. Uma destas classes, a Redução de Dados, atua na redução do número de transmissões e é o foco deste trabalho. Nas RSSFs o gasto de energia elétrica devido à transmissão de dados entre os nós sensores e a estação-base, em geral, é a maior parcela do consumo. Diversas abordagens no sentido de suprimir o envio das informações existem e uma delas é a supressão do envio de dados através da predição dos valores num modelo matemático (Liu et al., 2005). Neste trabalho comparamos quatro modelos de predição aplicados a séries temporais, são eles: ARIMA, SVM e MLP/ANN e LSTM/RNN, para verificar, em situações diversas, qual apresenta maior eficiência energética através da redução de dados transmitidos.

Para os cenários e dados coletados, o modelo SVM apresentou um desempenho superior aos modelos ARIMA, MLP/ANN e LSTM/RNN, sendo mais preciso nas predições, economizando mais energia das baterias da RSSF, evitando mais transmissões desnecessárias, e tendo um esforço computacional menor que os demais. Em seguida, o modelo baseado no ARIMA se mostrou, na maioria dos casos, mais eficiente energeticamente que os modelos baseados em redes neurais.

Um ponto importante que deve ser mencionado é quanto à margem para utilização ou não dos dados preditos. Neste trabalho esta margem é representada pelo δ . Este fator é responsável diretamente pela quantidade de dados suprimidos, pois quanto maior a margem, mais dados deixam de ser transmitidos. A variação do δ de 0,2 até 0,7 proporcionou uma

variação no erro (diferença entre a curva real e a curva predita) menor do que a variação positiva da eficiência energética, ou seja, com uma curva predita menos acurada, foi possível obter uma economia de energia maior, em alguns casos maior que 10%. Sendo assim, a eficiência energética está relacionada a esta margem, e a depender da grandeza que se está monitorando, o δ pode ser maior ou menor.

Trabalhos anteriores já avaliaram o modelo SVM isoladamente aplicado para eficiência energética de RSSF, no entanto este trabalho ratifica a sua qualidade quando comparado com outros modelos, confirmando assim a sua eficácia e valor dentro das pesquisas.

5.2 Trabalhos Futuros

- Dentro das técnicas de Redução de Dados ampliar a comparação com outros modelos de predição de dados e modelos híbridos;
- Avaliar de forma mais aprofundada o impacto computacional dos modelos sendo executados com os recursos dos nós sensores;
- Avaliar o impacto no consumo de energia em RSSFs mesclando classes diferentes de técnicas de eficiência energética;
- Elaborar artigo técnico com um *survey* das técnicas de redução de dados baseado em predição de séries temporais.

REFERÊNCIAS BIBLIOGRÁFICAS

- Abdolkarimi, M., Adabi, S. & Sharifi, A. (2018), 'A new multi-objective distributed fuzzy clustering algorithm for wireless sensor networks with mobile gateways', *AEU-INTERNATIONAL JOURNAL OF ELECTRONICS AND COMMUNICATIONS* **89**, 92–104.
- Aderohunmu, F. A., Brunelli, D., Deng, J. D. & Purvis, M. K. (2015), 'A Data Acquisition Protocol for a Reactive Wireless Sensor Network Monitoring Application', *SENSORS* **15**(5), 10221–10254.
- Akyildiz, I., Su, W., Sankarasubramaniam, Y. & Cayirci, E. (2002), 'Wireless sensor networks: a survey', *Computer Networks* **38**(4), 393 – 422. URL <http://www.sciencedirect.com/science/article/pii/S1389128601003024>.
- Amidi, A. (2014), ARIMA based Value Estimation in Wireless Sensor Networks, *in* Karimipour, F and Abbaspour, RA, ed., '1ST ISPRS INTERNATIONAL CONFERENCE ON GEOSPATIAL INFORMATION RESEARCH', Vol. 40 of *International Archives of the Photogrammetry Remote Sensing and Spatial Information Sciences*, ISPRS, pp. 41–46. 1st ISPRS International Conference on Geospatial Information Research, Tehran, IRAN, NOV 15-17, 2014.
- Aquino, A. L. L. (2011), A Framework for Sensor Stream Reduction in Wireless Sensor Networks, *in* Hovem, JM and Ellul, J and Gomez, L and Reddy, Y, ed., 'PROCEEDINGS OF SENSORCOMM 2011, THE FIFTH INTERNATIONAL CONFERENCE ON SENSOR TECHNOLOGIES AND APPLICATIONS', IARIA, IARIA XPS PRESS, PO BOX 7827, WILMINGTON, DE 19803 USA, pp. 30–35. 5th International Conference on Sensor Technologies and Applications (SENSORCOMM) / 1st International Workshop on Sensor Networks for Supply Chain Management (WSNSCM), Nice, FRANCE, AUG 21-27, 2011.
- Aquino, A. L. L., Junior, O. S., Frery, A. C., de Albuquerque, E. L. & Mini, R. A. F. (2014), 'MuSA: Multivariate Sampling Algorithm for Wireless Sensor Networks', *IEEE TRANSACTIONS ON COMPUTERS* **63**(4), 968–978.
- Aquino, A. L. L., Loureiro, A. A. F., Fernandes, A. O. & Mini, R. A. F. (2008), An In-Network Reduction Algorithm for Real-time Wireless Sensor Network Applications, *in* 'WMUNEP'08 : PROCEEDINGS OF THE FOURTH ACM INTERNATIONAL WORKSHOP ON WIRELESS MULTIMEDIA NETWORKING AND PERFORMANCE MODELING', ACM SIGSIM, ASSOC COMPUTING MACHINERY, 1515 BROADWAY, NEW YORK, NY 10036-9998 USA, pp. 18–25. 4th ACM International Workshop on Wireless Multimedia Networking and Performance Modeling (WMuNeP 2008), Vancouver, CANADA, OCT 27, 2008.

- Arunraja, M., Malathi, V. & Sakthivel, E. (2016), 'An Adaptive Prediction Framework for Energy Efficient Wireless Sensor Networks', *AD HOC & SENSOR WIRELESS NETWORKS* **33**(1-4), 199–221.
- Babayo, A. A., M. H. A. I. (2017), 'A review on energy management schemes in energy harvesting wireless sensor networks', *Renewable and Sustainable Energy Reviews*.
- Benardos, P. & Vosniakos, G.-C. (2007), 'Optimizing feedforward artificial neural network architecture.', *Eng. Appl. of AI* **20**, 365–382.
- Bouktif, S., Fiaz, A., Ouni, A. & Serhani, M. A. (2018), 'Optimal Deep Learning LSTM Model for Electric Load Forecasting using Feature Selection and Genetic Algorithm: Comparison with Machine Learning Approaches', *ENERGIES*.
- Box, P. & Jenkins, G. (1976), 'Time series analysis, forecasting and control', *Holden-Day, San Francisco, CA*.
- Chen, A.-S., Leung, M. T. & Daouk, H. (2003), 'Application of neural networks to an emerging financial market: forecasting and trading the taiwan stock index', *Computers Operations Research* **30**(6), 901 – 923. *Operation Research in Emerging Economics*.
- Cortes, C. & Vapnik, V. (1995), 'Support-Vector Networks', *Machine Learning* **20**(3), 273–297.
- Goodwin, P. & Lawton, R. (1999), 'On the asymmetry of the symmetric mape', *International Journal of Forecasting* **15**(4), 405 – 408. URL <http://www.sciencedirect.com/science/article/pii/S0169207099000072>.
- Han, K., Luo, J., Liu, Y. & Vasilakos, A. V. (2013), 'Algorithm design for data communications in duty-cycled wireless sensor networks: A survey', *IEEE Communications Magazine* **51**(7), 107–113.
- Heinzelman, W. B., Chandrakasan, A. P. & Balakrishnan, H. (2002), 'An application-specific protocol architecture for wireless microsensor networks', *IEEE Transactions on Wireless Communications* **1**(4), 660–670.
- Hochreiter, S. & Schmidhuber, J. (1997), 'Long short-term memory', *Neural computation* **9**, 1735–80.
- Huang, P., Xiao, L., Soltani, S., Mutka, M. W. & Xi, N. (2013), 'The evolution of mac protocols in wireless sensor networks: A survey', *IEEE Communications Surveys Tutorials* **15**(1), 101–120.
- Hyndman, R. J. & Khandakar, Y. (2008), 'Automatic time series forecasting: The forecast package for r', *Journal of Statistical Software*.

- Jaber, A., Abou Taam, M., Makhoul, A., Abou Jaoude, C., Zahwe, o. & Harb, H. (2017), 'Reducing the data transmission in sensor networks through kruskal-wallis model', *13th IEEE International Conference on Wireless and Mobile Computing, Networking and Communications (WiMob)*.
- Jan, B., Farman, H., Javed, H., Montrucchio, B., Khan, M. & Ali, S. (2017), 'Energy Efficient Hierarchical Clustering Approaches in Wireless Sensor Networks: A Survey', *WIRELESS COMMUNICATIONS & MOBILE COMPUTING*.
- Jiang, X. & Wah, A. (2003), 'Constructing and training feed-forward neural networks for pattern classification', *PATTERN RECOGNITION* **36**(4), 853–867.
- Khashei, M. & Bijari, M. (2011), 'A novel hybridization of artificial neural networks and ARIMA models for time series forecasting', *APPLIED SOFT COMPUTING* **11**(2), 2664–2675.
- Khashei, M., Bijari, M. & Hejazi, S. R. (2012), 'Combining seasonal arima models with computational intelligence techniques for time series forecasting', *Soft Computing* **16**(6), 1091–1105.
- Khashei, M., Hejazi, S. R. & Bijari, M. (2008), 'A new hybrid artificial neural networks and fuzzy regression model for time series forecasting', *Fuzzy Sets and Systems* **159**(7), 769 – 786. Theme: Fuzzy Models and Approximation Methods.
- Kim, H. Y. & Won, C. H. (2018), 'Forecasting the volatility of stock price index: A hybrid model integrating lstm with multiple garch-type models', *Expert Systems with Applications* **103**, 25 – 37. URL <http://www.sciencedirect.com/science/article/pii/S0957417418301416>.
- Leski, J. M. & Czogala, E. (1999), 'A new artificial neural network based fuzzy inference system with moving consequents in if-then rules and selected applications', *Fuzzy Sets and Systems* **108**, 289–297.
- Liu, C., Wu, K. & Tsao, M. (2005), 'Energy Efficient Information Collection with the ARIMA model in Wireless Sensor Networks', *IEEE Communications*.
- Maia, G., Aquino, A. L., Guidoni, D. L. & Loureiro, A. A. (2013), 'A multicast reprogramming protocol for wireless sensor networks based on small world concepts', *Journal of Parallel and Distributed Computing* **73**(9), 1277 – 1291. URL <http://www.sciencedirect.com/science/article/pii/S0743731513001111>.
- Moghadam, R. A. & Keshmirpour, M. (2011), Hybrid ARIMA and Neural Network Model for Measurement stimation in Energy-Efficient Wireless Sensor Networks, in 'Informatics Engineering and Information Science, PT III', Vol. 253 of *Communications in Computer and Information Science*, pp. 35–48.

- Pai, P. & Hong, W. (2005), 'Support vector machines with simulated annealing algorithms in electricity load forecasting', *Energy Conversion and Management* **46**(17), 2669–2688.
- Pai, P. & Lin, C. (2005), 'A hybrid ARIMA and support vector machines model in stock price forecasting', *Omega-International Journal of Management Science* **33**(6), 497–505.
- Perez-Marin, D., Garrido-Varo, A. & Guerrero, J. E. (2007), 'Non-linear regression methods in NIRS quantitative analysis', *TALANTA* **72**(1), 28–42.
- Raza, U., Bogliolo, A., Freschi, V., Lattanzi, E. & Murphy, A. L. (2016), 'A two-prong approach to energy-efficient WSNs: Wake-up receivers plus dedicated, model-based sensing', *AD HOC NETWORKS* **45**, 1–12.
- Ruan, J. & Lu, Z. (2018), 'A SELF-ADAPTIVE SPATIAL-TEMPORAL CORRELATION PREDICTION ALGORITHM TO REDUCE DATA TRANSMISSION IN WIRELESS SENSOR NETWORKS', *INTERNATIONAL JOURNAL OF INNOVATIVE COMPUTING INFORMATION AND CONTROL* **14**(3), 997–1013.
- Ruela, A. S., Cabral, R. S. & Aquino, Andre L. L. Guimaraes, F. G. (2009), Evolutionary design of wireless sensor networks based on complex networks, *in* 'Proceedings of the 2009 Fifth International Conference on Intelligent Sensors, Sensor Networks and Information Processing', pp. 237–242.
- Sachan, V. K., Imam, S. A. & Beg, M. T. (2017), 'Energy-Efficient Techniques in Wireless Sensor Networks: A Survey', *Journal of Active and Passive Electronic Devices* **12**(3-4), 309–351.
- Santi, P. (2005), 'Topology control in wireless ad hoc and sensor networks', *ACM COMPUTING SURVEYS* **37**(2), 164–194.
- Silva Junior, O., Aquino, A. L. L., Mini, R. A. F. & Figueiredo, C. M. S. (2009), Multivariate Reduction in Wireless Sensor Networks, *in* 'ISCC: 2009 IEEE SYMPOSIUM ON COMPUTERS AND COMMUNICATIONS, VOLS 1 AND 2', IEEE Symposium on Computers and Communications ISCC, IEEE, IEEE, 345 E 47TH ST, NEW YORK, NY 10017 USA, pp. 725+. IEEE Symposium on Computers and Communications (ISCC 2009), Sousse, TUNISIA, JUL 05-08, 2009.
- Soua, R. & Minet, P. (2011), 'A survey on energy efficient techniques in wireless sensor networks', *WNNC 2011 - 4th Joint IFIP Wireless and Mobile Networking Conferences*.
- Thawornwong, S. & Enke, D. (2004), 'The adaptive selection of financial and economic variables for use with artificial neural networks', *NEUROCOMPUTING* **56**, 205–232.
- Wang, X., Wang, S., Ma, J. & Bi, D. (2008), 'Energy efficient organization of wireless sensor networks with adaptive forecasting', *SENSORS* **8**(4), 2604–2616.

- Wong, B. K., Lai, V. S. & Lam, J. (2000), 'A bibliography of neural network business applications research: 1994–1998', *Computers Operations Research* **27**(11), 1045 – 1076.
- Xiao-Ying, D., Ding-Hui, Y., Tao, L. & Jing, X. (2009), 'Study on Mercer condition extension of support vector regression based on Ricker wavelet kernel', *Chinese Journal of Geophysics-Chinese Edition* **52**(9), 2335–2344.
- Yuan, C., Liu, S. & Fang, Z. (2016), 'Comparison of china's primary energy consumption forecasting by using arima (the autoregressive integrated moving average) model and gm(1,1) model', *Energy* **100**, 384 – 390.
- Zhang, G. (2003), 'Time series forecasting using a hybrid ARIMA and neural network model', *Neurocomputing* **50**(Supplement C), 159 – 175.
- Zhang, G., Patuwo, E. & Hu, M. Y. (1998), 'Forecasting with artificial neural networks: the state of the art', *International Journal of Forecasting* **14**(14), 35–62.
- Zhang, H., Zhang, X. & Sung, D. K. (2015), 'Lightweight Self-Adapting Linear Prediction Algorithms for Wireless Sensor Networks', *IEEE SENSORS JOURNAL* **15**(5), 3050–3058.
- Zuhairy, R. M. & Al Zamil, M. G. H. (2018), 'Energy-efficient load balancing in wireless sensor network: An application of multinomial regression analysis', *INTERNATIONAL JOURNAL OF DISTRIBUTED SENSOR NETWORKS*.

Este trabalho foi redigido em \LaTeX utilizando uma modificação do estilo IC-UFAL. As referências bibliográficas foram preparadas no JabRef e administradas pelo \BIBTeX com o estilo LaCCAN. O texto utiliza fonte Fourier-GUTenberg e os elementos matemáticos a família tipográfica Euler Virtual Math, ambas em corpo de 12 pontos.