Programa de Pós-Graduação em Instrumentação, Controle e Automação de Processos de Mineração (PROFICAM)
Escola de Minas, Universidade Federal de Ouro Preto (UFOP)
Associação Instituto Tecnológico Vale (ITV)

Dissertação

PREDIÇÃO DO TEOR DE FERRO EM PROCESSO DE BENEFICIAMENTO MINERAL USANDO MODELO AUTORREGRESSIVO

Vinícius Geraldo Rodrigues Gomes

Ouro Preto
Minas Gerais, Brasil
2020

Vinícius Geraldo Rodrigues Gomes

PREDIÇÃO DO TEOR DE FERRO EM PROCESSO DE BENEFICIAMENTO MINERAL USANDO MODELO AUTORREGRESSIVO

Dissertação apresentada ao Programa de Pós-Graduação em Instrumentação, Controle e Automação de Processos de Mineração da Universidade Federal de Ouro Preto e do Instituto Tecnológico Vale, como parte dos requisitos para obtenção do título de Mestre em Engenharia de Controle e Automação.

Orientador: Prof. Thiago Antônio Melo Euzébio, D.Sc.
Coorientador: Prof. Moisés Tavares da Silva, D.Sc.

Ouro Preto
2020

SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

G633p Gomes, Vinícius Geraldo Rodrigues .
Predição do Teor de Ferro em Processo de Beneficiamento Mineral usando Modelo Autorregressivo. [manuscrito] / Vinícius Geraldo Rodrigues Gomes. - 2020.
107 f.: il.: color., gráf., tab..

Orientador: Prof. Dr. Thiago Antônio Melo Euzébio.
Coorientador: Prof. Dr. Moisés Tavares da Silva.
Dissertação (Mestrado Profissional). Universidade Federal de Ouro Preto. Programa de Mestrado Profissional em Instrumentação, Controle e Automação de Processos de Mineração. Programa de Pós-Graduação em Instrumentação, Controle e Automação de Processos de Mineração.
Área de Concentração: Engenharia de Controle e Automação de Processos Minerais.

1. Análise de séries temporais . 2. Controle de processo - Métodos estatísticos - Modelos Autorregressivos (AR). 3. Métodos experimentais - Mínimos Quadrados Recursivos (MQR). 4. Beneficiamento de minério. I. Euzébio, Thiago Antônio Melo. II. Silva, Moisés Tavares da. III. Universidade Federal de Ouro Preto. IV. Título. CDU 681.5:622.2

Bibliotecário(a) Responsável: Maristela Sanches Lima Mesquita - CRB-1716

MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE OURO PRETO
REITORIA
ESCOLA DE MINAS
PROGR. POS GRAD. PROF. INST. CONT. E AUT. PROCESSOS DE MIN.

FOLHA DE APROVAÇÃO

Vinícius Geraldo Rodrigues Gomes

Predição do Teor de Ferro em Processo de Beneficiamento Mineral Usando Modelo Autorregressivo

Membros da banca

Thiago Antonio Melo Euzébio – Doutor - Instituto Tecnológico Vale Mineração
Moisés Tavares da Silva – Doutor - Instituto Tecnológico Vale Mineração
George Acioli Junior – Doutor - Universidade Federal de Campina Grande
Paulo Marcos de Barros Monteiro – Doutor - Universidade Federal de Ouro Preto
Luciano Perdigão Cota – Doutor - Instituto Tecnológico Vale Mineração

Versão final
Aprovado em 11 de Setembro de 2020

De acordo,

Agnaldo José da Rocha Reis.

Documento assinado eletronicamente por **Agnaldo Jose da Rocha Reis**, **COORDENADOR(A) DO CURSO DE PÓS-GRADUACÃ EM INSTRUMENTAÇÃO, CONTROLE E AUTOMAÇÃO DE PROC DE MINERAÇÃO**, em 18/11/2020, às 09:11, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do Decreto nº 8.539, de 8 de outubro de 2015.

A autenticidade deste documento pode ser conferida no site http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0 , informando o código verificador **0103663** e o código CRC **5F462334**.

R. Diogo de Vasconcelos, 122, - Bairro Pilar Ouro Preto/MG, CEP 35400-000
Telefone: - www.ufop.br

Agradecimentos

Agradeço aos meus pais, Vitorino e Efigênia, que lutaram sempre para garantir que eu tivesse acesso à educação e ao ensino de qualidade. MUITO OBRIGADO por todo carinho com que sempre fui tratado, por compreenderem as minhas dificuldades e deficiências e por formarem meu caráter através do exemplo e do amor. Dedico mais esta vitória a vocês.

Um agradecimento mais do que especial ao amor da minha vida, Camila, que foi minha sustentação durante este período tão turbulento, e aos nossos filhos, Guilherme e Luísa, por serem compreensíveis nos meus momentos de ausência e por saberem sempre os momentos exatos em que eu mais precisava de seus carinhos e amor verdadeiro.

Agradeço ao professor Thiago Euzébio, por participar desde o início desta etapa tão importante, e por compreender e me auxiliar a superar os diversos desafios com os quais nos deparamos. Agradeço também ao professor Moisés, que foi crucial para que este trabalho pudesse ser concluído, por me direcionar e orientar tão brilhantemente até este encerramento.

Agradeço à Vale, por me propiciar esta experiência, que tornar-se-ia praticamente impossível de ser realizada, não fosse através deste programa, visto minha rotina profissional e momento atual de vida pessoal. Agradeço também aos gestores, que enxergaram em mim potencial de realizar esta tarefa e disponibilizaram toda infraestrutura necessária para sua realização.

Por fim, a Deus, que me propiciou todas estas vivências, pela força, persistência e saúde, indispensáveis durante toda esta etapa.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, Brasil (CAPES), Código de Financiamento 001; do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq); da Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG); e da Vale SA

"Education is the path from cocky
ignorance to miserable uncertainty"
(Mark Twain).

Resumo

Resumo da Dissertação apresentada ao Programa de Pós Graduação em Instrumentação, Controle e Automação de Processos de Mineração como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

PREDIÇÃO DO TEOR DE FERRO EM PROCESSO DE BENEFICIAMENTO MINERAL USANDO MODELO AUTORREGRESSIVO

Vinícius Geraldo Rodrigues Gomes

Setembro/2020

Orientadores: Thiago Antônio Melo Euzébio
Moisés Tavares da Silva

A tarefa de medir o teor de ferro do minério processado em uma usina é complexo, mas fundamental para o bom desempenho da operação. Em geral, esta medição é realizada por meio de análise laboratorial que insere um atraso de algumas horas na obtenção dos resultados. Neste trabalho é realizada a predição do teor de ferro a partir dos dados históricos das análises laboratoriais. Estes dados indicam os teores dos materiais alimentados em uma etapa de concentração magnética e uma etapa de flotação reversa de duas unidades distintas de beneficiamento mineral da mineradora Vale S.A. Inicialmente, são realizadas análises de estacionariedade, autocorrelação e autocorrelação parcial. Em seguida, são usados modelos autorregressivos e o algoritmo de mínimos quadrados recursivos para predição do teor de ferro. Os resultados demonstram o bom desempenho do modelo na tarefa de efetivamente predizer as amostras futuras e indicar tendências ascendentes ou descendentes do teor de ferro, auxiliando, assim, os engenheiros de automação e de processos das plantas na tomada de decisões.

Palavras-chave: Séries Temporais, Mínimos Quadrados Recursivos, Modelo Autorregressivo.

Macrotema: Usina; **Linha de Pesquisa:** Instrumentação no Processamento de Minérios; **Tema:** Redução de Variabilidade e Melhoria de Controle; **Área Relacionada da Vale:** Concentração Mineral.

Abstract

Abstract of Dissertation presented to the Graduate Program on Instrumentation, Control and Automation of Mining Process as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

IRON ORE GRADE PREDICTION IN MINERAL PROCESSING PLANT USING AUTO-REGRESSIVE MODEL

Vinícius Geraldo Rodrigues Gomes

September/2020

Advisors: Thiago Antônio Melo Euzébio
Moisés Tavares da Silva

The task of measuring the iron content of ore processed at a plant is complex, but essential to the performance of the operation. In general, this measurement is carried out by means of laboratory analysis which produces a delay of several hours in obtaining the results. In this work, the iron content prediction is made from the historical data of the laboratory analyzes. These datas indicates the contents of the material that feeds a stage of magnetic concentration and a stage of reverse flotation from two distincts mineral processing units of the mining company Vale S.A. Initially, analyzes of stationarity, autocorrelation and partial autocorrelation are performed. Then, autoregressive models and the recursive least squares algorithm are used to predict the iron content. The results show good performance of the model in the task of effectively predicting future samples and indicating behavior ascending or descending trends, thus, assisting process engineer and control and automation engineer in making decisions.

Keywords: Time Series, Recursive Least Squares, Autoregressive Model.

Macrotheme: Processing Plant; **Research Line:** Instrumentation in Mineral Processing; **Theme:** Variability Reduction and Control Improvement; **Related Area of Vale:** Mineral Beneficiation.

Lista de Figuras

Figura 1.1 Evolução da produção mundial aço 12
Figura 1.2 Evolução da produção mundial de minério de ferro 12
Figura 1.3 Variação histórica do teor de ferro - Concentração Magnética 15
Figura 1.4 Variação histórica do teor de sílica - Concentração Magnética 15

Figura 2.1 Fluxograma do processo de beneficiamento mineral de Mina Fábrica 21
Figura 2.2 Diagrama do circuito de concentração magnética de Minas Fábrica 23
Figura 2.3 Concentrador magnético WHIMS - Jones 24
Figura 2.4 Exemplo de matriz magnética 24
Figura 2.5 Esquema sequencial de funcionamento do concentrador WHIMS 25
Figura 2.6 Exemplo de matriz magnética entupida 27
Figura 2.7 Fluxograma do processo de beneficiamento da ITMI de Vargem Grande . . 28
Figura 2.8 Diagrama do peneiramento da ITMI de Vargem Grande 29
Figura 2.9 Diagrama do circuito de flotação reversa da ITMI de Vargem Grande 31
Figura 2.10 Representação de uma célula de flotação do tipo *Tankcell* 32

Figura 3.1 Diagrama da arquitetura do sistema PIMS 35
Figura 3.2 Diagrama da nova arquitetura do sistema PIMS 37
Figura 3.3 Comportamento do teor de ferro (amostrado) - Concentração Magnética . . 39
Figura 3.4 Comportamento do teor de ferro (interpolado) - Concentração Magnética . . 40
Figura 3.5 Comportamento do teor de sílica (amostrado) - Concentração Magnética . . 40
Figura 3.6 Comportamento do teor de sílica (interpolado) - Concentração Magnética . 41
Figura 3.7 Comportamento do teor de ferro (amostrado) - Flotação Reversa 42
Figura 3.8 Representação da topologia do Sistema Labview 43

Figura 4.1 *ACF* do teor de ferro (amostrado) - Concentração Magnética 46
Figura 4.2 *ACF* do teor de ferro (interpolado) - Concentração Magnética 47
Figura 4.3 *ACF* do teor de sílica (amostrado) - Concentração Magnética 47
Figura 4.4 *ACF* do teor de sílica (interpolado) - Concentração Magnética 48
Figura 4.5 *ACF* do teor de ferro (amostrado) - Flotação Reversa 49
Figura 4.6 *PACF* do teor de ferro (amostrado) - Concentração Magnética 50
Figura 4.7 *PACF* do teor de ferro (interpolado) - Concentração Magnética 51

Figura 4.8 *PACF* do teor de sílica (amostrado) - Concentração Magnética 51
Figura 4.9 *PACF* do teor de sílica (interpolado) - Concentração Magnética 52
Figura 4.10 *PACF* do teor de ferro (amostrado) - Flotação Reversa 53
Figura 4.11 Fluxograma para identificação de sistemas 54
Figura 4.12 Diagrama do arranjo geral do médodo dos Mínimos Quadrados 56
Figura 4.13 Resultado da predição ferro amostrado - Concentração Magnética - $\lambda = 1$. 64
Figura 4.14 Erros da predição ferro amostrado - Concentração Magnética - $\lambda = 1$ 64
Figura 4.15 Parâmetros da predição ferro amostrado - Concentração Magnética - $\lambda = 1$. 65
Figura 4.16 Resultado da predição ferro amostrado - Concentração Magnética - $\lambda = 0{,}5$ 66
Figura 4.17 Erros da predição ferro amostrado - Concentração Magnética - $\lambda = 0{,}5$ . . . 66
Figura 4.18 Parâmetros da predição ferro amostrado - Concentração Magnética - $\lambda = 0{,}5$ 67
Figura 4.19 Resultado da predição ferro interpolado - Concentração Magnética - $\lambda = 1$. 69
Figura 4.20 Erros da predição ferro interpolado - Concentração Magnética - $\lambda = 1$ . . . 69
Figura 4.21 Parâmetros da predição ferro interpolado - Concentração Magnética - $\lambda = 1$ 70
Figura 4.22 Resultado da predição sílica amostrado - Concentração Magnética - $\lambda = 1$. 72
Figura 4.23 Erros da predição sílica amostrado - Concentração Magnética - $\lambda = 1$ . . . 72
Figura 4.24 Parâmetros da predição sílica amostrado - Concentração Magnética - $\lambda = 1$ 73
Figura 4.25 Resultado da predição sílica interpolado - Concentração Magnética - $\lambda = 1$. 75
Figura 4.26 Erros da predição sílica interpolado - Concentração Magnética - $\lambda = 1$ . . . 75
Figura 4.27 Parâmetros da predição sílica interpolado - Concentração Magnética - $\lambda = 1$ 76
Figura 4.28 Resultado da predição ferro amostrado - Flotação Reversa - $\lambda = 1$ 77
Figura 4.29 Erros da predição ferro amostrado - Flotação Reversa - $\lambda = 1$ 78
Figura 4.30 Parâmetros da predição ferro amostrado - Flotação Reversa - $\lambda = 1$ 78

Figura 5.1 Interface da aplicação usando dados *offline* 81
Figura 5.2 Código Labview da aplicação usando dados *offline* 82
Figura 5.3 Interface da aplicação usando dados *online* - tendência negativa 84
Figura 5.4 Interface da aplicação usando dados *online* - tendência positiva 84
Figura 5.5 VI utilizado para comunicar com o sistema PIMS PI 86
Figura 5.6 *Loop* responsável pela leitura dos valores do PIMS PI 87
Figura 5.7 *Loop* utilizado para gerar os primeiros parâmetros do modelo AR(2) 89
Figura 5.8 *Loop* responsável pelas iterações e predição do teor 90

Lista de Tabelas

Tabela 2.1 Efeitos de dosagem descontrolada de reagentes 33

Tabela 4.1 Comportamentos teóricos para modelos estacionários. 52
Tabela 4.2 Resultados de predição ferro amostrado - Concentração Magnética 63
Tabela 4.3 Resultados de predição ferro interpolado - Concentração Magnética 68
Tabela 4.4 Resultados de predição sílica amostrado - Concentração Magnética 71
Tabela 4.5 Resultados de predição sílica interpolado - Concentração Magnética 74
Tabela 4.6 Resultados de predição ferro amostrado - Flotação Reversa 77

Sumário

1 Introdução **12**

1.1 Contexto 12

1.2 Motivação 14

1.3 Objetivos 15

1.3.1 Objetivos específicos 16

1.4 Revisão Bibliográfica 16

1.4.1 Técnicas para predição de séries temporais 16

1.4.2 Aplicações na indústria mineral 17

1.5 Questões da Pesquisa 17

1.6 Contribuições da Pesquisa 18

1.7 Organização do Trabalho 18

2 Beneficiamento Mineral **20**

2.1 Separação Magnética - Mina de Fábrica 20

2.1.1 Etapas de pré-processamento mineral 20

2.1.2 O Circuito de Concentração Magnética de Mina Fábrica 22

2.1.3 Concentrador Magnético de Mina Fábrica 24

2.1.4 Benefícios do Trabalho na Concentração Magnética 26

2.2 Flotação 27

2.2.1 Etapas de pré-processamento 27

2.2.2 O Circuito de Flotação Reversa da ITMI de Vargem Grande 30

2.2.3 Células de Flotação (*Tank Cell*) 31

2.2.4 Benefícios do Trabalho na Flotação Reversa 32

3 Material e Métodos **34**

3.1 Arquitetura dos Sistemas de Automação 34

3.1.1 Arquitetura do sistema de automação de Mina de Fábrica 34

3.1.2 Arquitetura do sistema de automação da ITMI de Vargem Grande . . . 36

3.1.3 Nova arquitetura do sistema PIMS 36

3.2 Coleta e tratamento dos dados 37

3.2.1 Dados da Concentração Magnética 37

3.2.2 Dados da Flotação Reversa 41
3.3 Estrutura Labview 42

4 Modelo Autorregressivo 44
4.1 Análise de Estacionariedade 45
4.2 Análise de Autocorrelação 45
4.3 Análise de Autocorrelação Parcial 49
4.4 Identificação dos Modelos 53
4.4.1 O Algoritmo dos Mínimos Quadrados 55
4.4.2 O Algoritmo dos Mínimos Quadrados Recursivos 56
4.5 Avaliação de Desempenho do Modelo 60
4.5.1 RMSE - *Root Mean Square Error* 60
4.5.2 MAPE - *Mean Absolute Percent Error* 60
4.5.3 Coeficiente U de Theil 60
4.6 Resultados da Predição do Modelo AR 61
4.6.1 Teor de Ferro na alimentação da concentração magnética da Mina de Fábrica 62
4.6.2 Teor de Sílica na alimentação da concentração magnética da Mina de Fábrica 70
4.6.3 Teor de ferro na alimentação da flotação reversa da ITMI de Vargem Grande 76

5 Labview - Implementação Prática 79
5.1 Aplicação usando dados *offline* 80
5.2 Aplicação usando dados *online* 83

6 Conclusões e Sugestões de Trabalhos Futuros 92
6.1 Conclusões 92
6.2 Sugestões de Trabalhos Futuros 93

Referências Bibliográficas 95

Apêndices 97

A Apêndice A: Consulta SQL 98

B Apêndice B: Código Matlab 103

1. Introdução

1.1. Contexto

A crescente demanda mundial por produtos industrializados tem levado ao aumento gradativo do consumo de minério de ferro. Como apresentado por Lu (2015), a produção de aço praticamente dobrou desde o ano 2000 e a produção de minério de ferro, principal matéria-prima utilizada na produção desta liga metálica, aumentou de 1,043 bilhão de toneladas no ano de 2001, para 2,93 bilhões de toneladas em 2012. As Figuras 1.1 e 1.2 detalham, respectivamente, o crescimento das produçãos mundias de aço, desde o ano de 1980, e de minério de ferro, desde o ano de 1992.

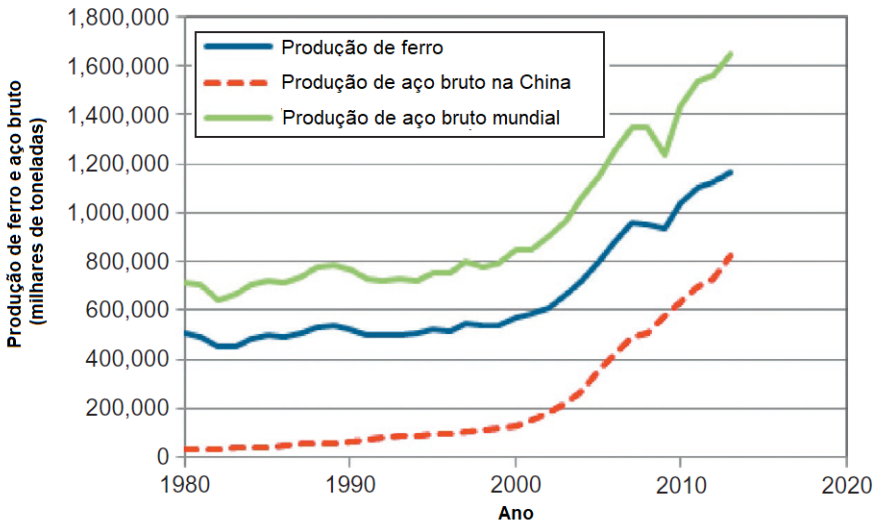

Figura 1.1: Evolução da produção mundial de aço, desde 1992. Fonte: Lu (2015)

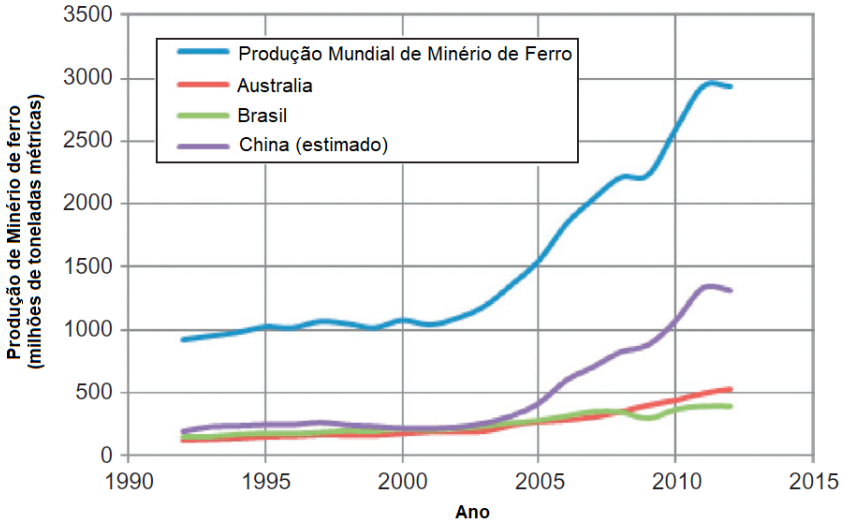

Figura 1.2: Evolução da produção mundial de minério de ferro, desde 1992. Fonte: Lu (2015)

As grandes empresas de produção mineral têm orientado seus esforços não apenas na obtenção de grandes volumes de produção, mas também na qualidade esperada de seus produtos. Contratos de fornecimento destas commodities apresentam, frequentemente, penalizações financeiras às empresas produtoras, caso haja alta variabilidade em seus teores. Estas penalidades podem ocorrer mesmo que tal variabilidade tenha gerado aumento do teor do mineral de interesse, visto que requisítos muito bem definidos dos teores dos contaminantes também são de grande importância para as empresas metalúrgicas, principalmente quando *blends* de minerais [1] de diferentes fornecedores são utilizados na produção do aço.

Em função da redução de reservas de alto teor de minério de ferro mundiais, processos de concentração mineral passaram a ter alta importância para as empresas mineradoras. Como apresentado por Holmes e Lu (2015), apesar de as reservas minerais existentes no norte do Brasil apresentarem teores de minério de ferro de cerca de 65-66%, o que representa uma vantagem comercial se comparado com as reservas australianas, as jazidas, já bastante exploradas do quadrilátero ferrífero mineiro, apresentam teores de cerca de 35-50%, requerendo, consequentemente, processos adicionais de beneficiamento mineral.

As técnicas de concentração mineral resumem-se à separação do mineral de interesse, no caso o minério de ferro, daqueles que não despertam o interesse econômico. Os principais processos de concentração mineral existentes podem ser subdivididos nos seguintes grupos de métodos: separação/concentração gravimétrica; separação magnética; flotação; seleção mecanizada. As principais técnicas utilizadas atualmente nas instalações de beneficiamento das minas do quadrilátero ferrífero de Minas Gerais são, como apresentado por Maré *et al.* (2015), a Separação Magnética e Flotação Reversa. Estas técnicas têm desempenhado importante papel neste beneficiamento, em função de sua alta capacidade de processamento, com possibilidade de atingir os teores e qualidade dos produtos demandados pelas empresas siderúrgicas, aliados a bons indicadores de recuperação metalúrgica.

Diversas variáveis são responsáveis pela eficiência dos processos de beneficiamento mineral e do circuito de beneficiamento, como um todo. Dentre estas variáveis, algumas são estáticas, sendo projetadas e definidas em projeto. Também existem diversas variáveis que podem ser manipuladas, sendo utilizadas como variáveis de controle. Estas variáveis são utilizadas para obter a qualidade esperada e especificada para os produtos minerais. No entanto, os teores dos materiais alimentados nos processos de concentração afetam diretamente o desempenho dos circuitos de beneficiamento, podendo ser tratados, do ponto de vista de controle de processos, como distúrbios. Tanto os processos de Flotação Reversa quanto de Separação Magnética apresentam uma grande complexidade de identificação e modelagem de seus comportamentos, em função da quantidade de variáveis envolvidas nos processos. Dada esta alta complexidade, como apresentado por Hodouin (2011), técnicas cada vez mais avançadas têm sido utilizadas na modelagem destes processos.

[1] *Blends* são misturas de minérios com diferentes teores de ferro e de contaminantes, que visam obter parâmetros específicos para certos processos.

Dentre as diversas variáveis de um processo de concentração mineral, os teores de ferro ($\%Fe$) e sílica ($\%SiO_2$) na alimentação podem ser considerados como distúrbios, sendo este último o principal contaminante. Os valores destas variáveis são obtidas através de análise laboratorial química, e possuem um tempo de amostragem de algumas horas (a depender da importância do ponto específico do processo de beneficiamento que está sendo amostrado). Este período de amostragem insere atraso em variáveis de extrema importância no processo de beneficiamento mineral. Ou seja, os teores dos materiais a serem alimentados no circuito de beneficiamento no momento atual só serão conhecidos horas após a sua entrada no mesmo. Assim, não é possível utilizar esta medida para monitoramento e consequentes adequações do processo, tais como: alteração de vazão do material alimentado, ajustes de densidade do material, controle de reagentes, *set-up* de equipamentos, dentre outros.

Neste contexto, visando redução de perdas na qualidade do produto e uma operação mais adequada às condições reais do material alimentado nesta etapa de processamento, a informação de predição do teor do material alimentado, ou mesmo a indicação de tendências ascendentes ou descendentes, podem tornar-se ferramenta essencial nesta etapa do beneficiamento mineral. A disponibilização da predição dos teores de ferro e sílica para o sistema de controle da planta, concede aos engenheiros de processo e de controle e automação, oportunidade de realizar as devidas alterações nos algoritmos de controle e nas receitas utilizadas nas etapas de concentração mineral, ao agregar variáveis que, até então, eram tratadas como distrúrbios.

1.2. Motivação

A Planta de beneficiamento mineral da Mina de Fábrica, da mineradora Vale S.A., localizada em Ouro Preto - MG, é composta por uma etapa de beneficiamento mineral e por uma etapa de pelotização. O produto alimentado na etapa de pelotização possui limites muito específicos de $\%SiO_2$ e, para o correto funcionamento desta etapa, é necessário haver um fluxo contínuo de *Pellet-Feed*[2]. Portanto, qualquer variação nos parâmetros de eficiência da concentração magnética afeta diretamente o desempenho da etapa de pelotização, acarretando prejuízos financeiros.

Durante dois meses de avaliação do desempenho da concentração magnética, da coleta realizada durante o ano de 2018, constatou-se que em, aproximadamente, 49% do período houve valores altos de SiO_2 (valores superiores a 6%), indicando que um excesso de minerais não ferromagnéticos estavam sendo carregados para o concentrado. Em aproximadamente, 19% do período houve valores baixos de %Fe no concentrado (valores inferiores a 62%), indicando que grande parte do Fe estava sendo carregado para o rejeito, diminuindo a recuperação metalúrgica do processo. As Figuras 1.3 e 1.4 representam as variações dos teores de ferro e sílica observadas no período em questão, respectivamente.

[2] *Pellet-Feed* é o produto de uma planta de beneficiamento mineral, destinado ao processo de pelotização, possuindo características físicas e químicas de acordo com as especificações.

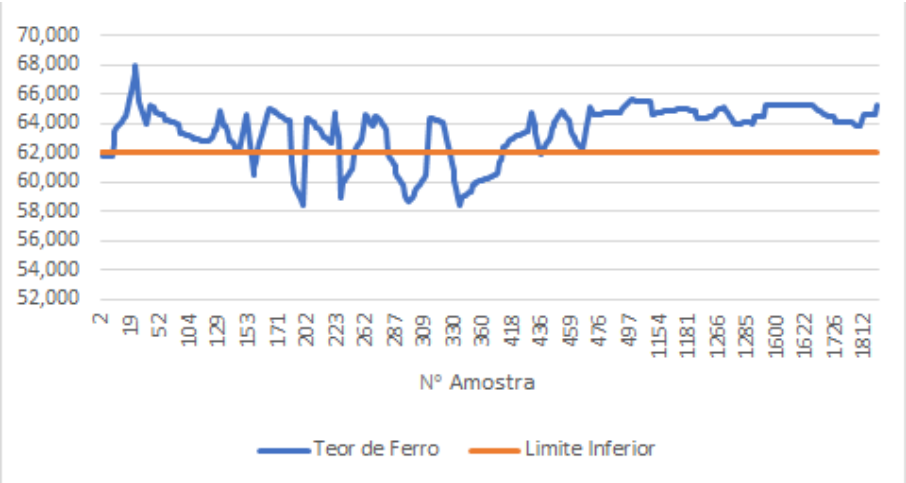

Figura 1.3: Variação histórica do teor de ferro no concentrado da etapa de Concentração Magnética. Fonte: elaborada pelo autor.

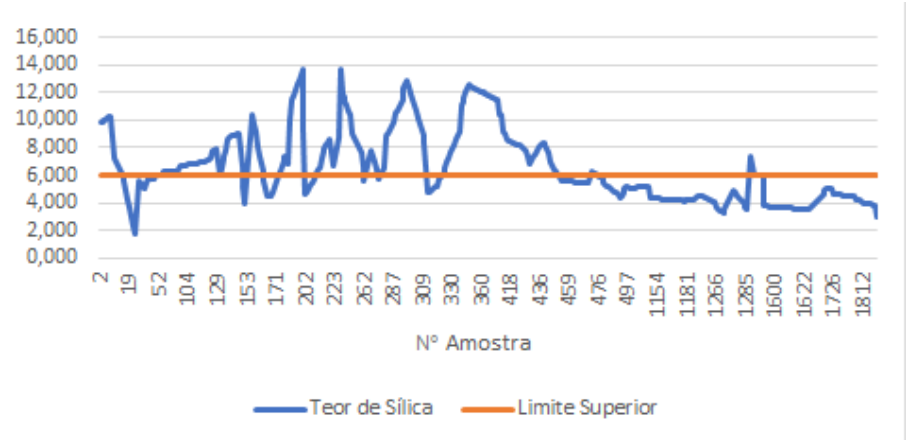

Figura 1.4: Variação histórica do teor de sílica no concentrado da etapa de Concentração Magnética. Fonte: elaborada pelo autor.

Estas ocorrências motivaram a realização do presente trabalho, visando disponibilizar antecipadamente as informações dos teores do material alimentado na etapa de concentração magnética, com assertividade suficiente para possibilitar o *set-up* dos parâmetros desse processo, de modo a reduzir os desvios apresentados.

1.3. Objetivos

Propor uma forma de estimação confiável dos teores de ferro dos materiais alimentados em processos de concentração de finos. Esta estimativa deve ser disponibilizada nos sistemas de controle das instalações de processamento mineral, a tempo de serem realizadas alterações nos parâmetros destes processos, que possibilitem a obtenção de produtos com a qualidade e volumes adequados.

1.3.1. Objetivos específicos

- Obter dados reais e relevantes de processos industriais de beneficiamento mineral;
- Realizar as análises necessárias para avaliação das séries temporais dos dados obtidos;
- Definir um modelo adequado para a predição do teor de ferro dos materiais alimentados nos processos de beneficiamento mineral;
- Desenvolver um algoritmo que possibilite a geração da informação em tempo hábil e a indicação da tendência dinâmica do teor de ferro;
- Implementar a solução proposta em alguma plataforma que possibilite aos engenheiros de processo e automação utilizar a informação fornecida para refinar as estratégias de controle e otimização dos processos de beneficiamento mineral;

1.4. Revisão Bibliográfica

Nesta seção é realizada uma revisão bibliográfica sobre as principais técnicas de predição de séries temporais. É realizada, também, uma revisão de como tais técnicas vem sendo aplicadas no ambiente industrial.

1.4.1. Técnicas para predição de séries temporais

Existem diferentes técnicas de predição de séries temporais, utilizadas de acordo com as restrições e objetivos que deseja-se alcançar. Em Weigend (2018) é apresentada uma comparação de diversas técnicas de predição de séries temporais. Análises são realizadas em diversos conjuntos de dados, considerando diferentes técnicas de predição, desde as tradicionais técnicas lineares, até modelos baseados em reconstrução por espaço de estados e redes neurais. Já em Fan e Yao (2008), são apresentados diversos métodos para a predição de séries não lineares, seja através de modelos paramétricos ou não.

O trabalho de Smith *et al.* (2002) apresenta a comparação de métodos para a predição de séries temporais relacionadas ao fluxo de tráfego de automóveis, considerando modelos paramétricos e não paramétricos. Já o trabalho de Weron e Misiorek (2008) também apresenta algumas comparações de métodos, neste caso, paramétricos e semi-paramétricos para a predição dos preços praticados no mercado de eletricidade. Uma outra abordagem, que considera a utilização de processos gaussianos na modelagem de séries temporais, é apresentada por Roberts *et al.* (2013).

Em Kamal e Jafri (1997) é utilizado um modelo autorregressivo com média móvel (ARMA) para a predição da velocidade do vento. Similarmente, Huang e Chalabi (1995) apresenta um trabalho para a predição de velocidade do vento, porém, neste caso, o modelo

proposto é autorregressivo (AR). Kitagawa e Gersch (1985) apresentam um trabalho em que um modelo autorregressivo, variante no tempo, é utilizado na representação de séries temporais com covariância não estacionária.

1.4.2. Aplicações na indústria mineral

O trabalho de Kumral (2015) demonstra como as variações nos teores dos minérios impactam financeiramente nos resultados de uma planta de processamento mineral e propõe uma estratégia de minimização de perdas, baseada em conceitos e técnicas de gestão da qualidade. Já Tasdemir (2013) apresenta uma análise de série temporal, através de um modelo autorregressivo de ordem 1 para determinar as correlações entre os teores de cromita e ferro nos fluxos de alimentação, concentrado e rejeito de uma planta de processamento de cromita. Por outro lado, Guo (2010) apresenta um estudo que propõe a utilização de simulação através de redes neurais para a estimação do teor de minério de ferro. Neste trabalho, propõe-se a utilização de um dispositivo portátil que, através da leitura de sensores de susceptibilidade magnética instalados *in loco*, possibilita a simulação e estimação dos teores.

Uma outra abordagem é apresentada por Mahmoudabadi *et al.* (2009), neste trabalho os autores propõem uma aproximação híbrida, baseada em rede neural, neste caso MLP (*Multilayer Perceptron*) e algoritmos genéticos, visando aumentar a eficiência da estimação dos teores de minério de ferro. Inicialmente, a rede MLP é utilizada para estimar os teores, posteriormente a abordagem híbrida é aplicada para refinar o procedimento de treinamento. De outra forma, Patel *et al.* (2017) apresentam um estudo em que propõem o desenvolvimento de um sistema de visão, utilizando o algoritmo SVR (*Support Vector Regression*) para realizar a predição, em tempo real, dos teores de ferro nos minerais presentes em correias transportadoras em movimento.

1.5. Questões da Pesquisa

Algumas questões foram levantadas no início deste trabalho visando nortear seu desenvolvimento e pautar as discussões que serão apresentadas nos próximos capítulos:

- Modelos Autorregressivos são suficientes para realizar a indicação de tendência ascendente ou descendente, dos teores de ferro e sílica dos materiais alimentados em processos de beneficiamento de finos, em escala industrial?
- Modelos Autorregressivos são suficientes para realizar a predição um passo a frente dos teores de ferro e sílica dos materiais alimentados em tais processos?
- A predição dos teores de diferentes instalações pode ser representada por modelos autorregressivos com mesma ordem?
- A utilização de dados interpolados, quando da ocorrência de amostras faltantes, gera alterações positivas ou negativas na estimação do modelo?

- É possível implementar um sistema que forneça automaticamente as informações de predição e tendências dos teores para os sistemas de controle dos respectivos processos?

1.6. Contribuições da Pesquisa

As contribuições apresentadas neste trabalho são:

- Utilizar modelos autorregressivo para representar a dinâmica do teor de ferro dos materiais alimentados nos principais processos de beneficiamento de finos - flotação reversa e concentração magnética;
- Utilizar o algoritimo dos Mínimos Quadrados Recursivos para capturar a variação dinâmica dos parâmetros do modelo ao longo do tempo;
- Implementar a solução proposta no ambiente LabView, realizando a comunicação direta com os dados amostrados de laboratório, através de interface específica com o sistema *Plant Information Management System* (PIMS).
- Disponibilizar a informação do teor de ferro estimado e das tendências crescentes ou descendentes para refinamento das estratégias dos sistemas de controle, através de protocolo *Ole for Process Control* (OPC).

1.7. Organização do Trabalho

Este trabalho foi organizado em 6 capítulos, sendo o primeiro referente à Introdução do mesmo. Neste capítulo foram apresentados o contexto em que este trabalho foi desenvolvido; a motivação para sua realização; os objetivos; a revisão bibliográfica dos temas envolvidos; as questões que nortearam o desenvolvimento do trabalho e as contribuições do mesmo.

No Capítulo 2 são apresentados os processos industriais de beneficiamento mineral, dos quais os dados utilizados neste trabalho foram obtidos. São demonstrados os detalhes das etapas específicas de beneficiamento mineral em questão, bem como o processamento inicial pelos quais os minerais são submetidos para que sejam alimentados em tais processos com as características ideais para o efetivo beneficiamento.

No Capítulo 3 são apresentados os materiais e métodos utilizados no desenvolvimento deste trabalho. São detalhados os contextos dos sistemas de automação das plantas industriais em questão, bem como as técnicas utilizadas nas análises e nos desenolvimentos realizados.

No Capítulo 4 são apresentadas as análises realizadas, bem como o desenvolvimento e validação dos algoritmos utilizados. Em cada seção é apresentado, inicialmente, o embasamento teórico que sustenta a análise ou desenvolvimento. Ao final das mesmas seções são apresentados os resultados obtidos em cada uma das etapas.

No Capítulo 5 é apresentado o contexto da implementação prática realizada. São demonstrados os pontos decisivos considerados para as devidas decisões tomadas, bem como todo o desenvolvimento realizado e a implementação prática efetivamente executada.

No Capítulo 6 são apresentadas as conclusões deste trabalho e as sugestões de pesquisas e desenvolvimentos futuros.

2. Beneficiamento Mineral

Conforme apresentado no capítulo anterior, este trabalho foi desenvolvido com intuito de agregar informações que possam auxiliar e refinar as estratégias de controle dos principais processos de concentração mineral de finos. As principais técnicas utilizadas atualmente nas instalações de beneficiamento das minas do quadrilátero ferrífero de Minas Gerais são, como apresentado por Maré *et al.* (2015), a separação magnética e flotação reversa. Dessa forma, um processo baseado em cada uma dessas técnicas foi escolhido e utilizado como base para o presente trabalho.

O processo de separação magnética que motivou e foi utilizado nestre trabalho, foi o da planta de beneficiamento mineral de Mina de Fábrica. Ao passo que o processo de flotação reversa utilizado foi o da planta de beneficiamento mineral da Instalação de Tratamento de Minério Itabirítico (ITMI) de Vargem Grande, também da mineradora Vale S.A., localizada em Nova Lima - MG.

Nas próximas seções são apresentados, de forma resumida, os processos das instalações escolhidas. Além disso, será apresentado, também, como a predição dos teores de ferro e sílica do mineral pode agregar valor às estratégias de controle e, consequentemente, à qualidade dos produtos destas duas instalações industriais.

2.1. Separação Magnética - Mina de Fábrica

O processo mineral que utiliza técnicas de concentração magnética, baseia-se nas diferentes susceptibilidades magnéticas de partículas do mineral (minério de ferro) e da ganga[1], quando expostas a um campo magnético, como propriedade diferenciadora. No caso de Mina Fábrica, este processo é realizado em uma planta de processamento a úmido, na qual o mineral passa por etapas de pré-processamento, garantindo que a polpa (mineral + água) esteja com o percentual de sólidos e densidades adequadas, assim como o mineral presente esteja com a granulometria ideal para ser beneficiado no circuito de concentração magnética.

2.1.1. Etapas de pré-processamento mineral

A Figura 2.1 representa o fluxograma das etapas do processo de beneficiamento mineral de Mina Fábrica.

[1]Material comercialmente sem valor e que é encontrado agregado aos minerais de interesse em um depósito mineral.

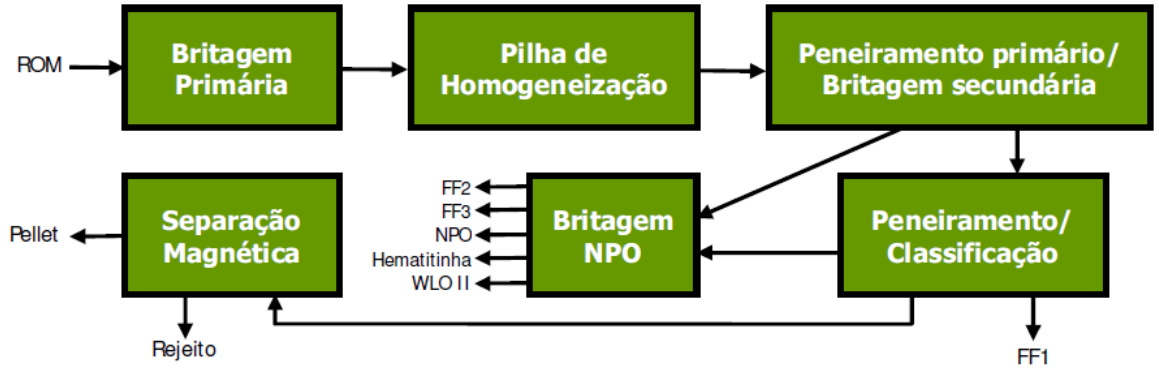

Figura 2.1: Fluxograma de etapas do processo de beneficiamento mineral de Mina Fábrica. Fonte:Val (2007)

O *Run Of Mine*[2] (ROM) é transportado até o britador primário através de caminhões (fora-de-estrada e rodoviários). A etapa de britagem primária, primeiro processo de cominuição da planta de beneficiamento de Mina Fábrica, é realizada por um britador giratório, que reduz a granulometria do material para valores inferiores a 150 mm. Após a britagem primária, o material é descarregado em um silo que atua como pulmão e é utilizado para garantir uma taxa média de transporte do material até o pátio de homogeneização. Através de uma empilhadeira, o material é empilhado em dois pátios paralelos, com capacidade de aproximadamente 180.000 toneladas, de forma planejada e definida pelas equipes de geologia. O pátio de homogeneização é utilizado para possibilitar que a retomada do material, a ser alimentado nas próximas etapas, não apresente grandes variações instantâneas, atuando como um filtro que reduz boa parte das variabilidades provenientes das frentes de lavra.

O material retomado do pátio de homogeneização é transpotado até um silo pulmão com volume de aproximadamente 2000 m^3. Alimentadores controlam a vazão do material de saída do silo, que é enviado para a etapa de peneiramento primário. Nesta etapa, o material deixa de ser processado a umidade natural, e passa a ter a adição de água nas peneiras vibratórias. O material passante das peneiras do primeiro estágio de peneiramento (-40mm) é direcionado para a etapa de peneiramento secundário, que possui corte de 8mm. O material retido nas peneiras vibratórias (+40mm) é direcionado para a britagem secundária, que é realizada por dois britadores cônicos, responsáveis pela segunda fase de cominuição do mineral. O material que passa pela segunda etapa de britagem se junta ao material retido no peneiramento secundário (-40mm, +8mm), e é direcionado para a etapa de britagem terciária, ou britagem *Natural Pellet Ore* (NPO). Após a etapa de britagem terciária já são obtidos alguns produtos granulados (+10mm), que não são objetos desse estudo. Os minerais de menor granulometria da britagem terciária retornam à primeira etapa de peneiramento, fechando assim o ciclo de cominuição e peneiramento de Mina Fábrica.

O fluxo de *underflow* [3] do peneiramento secundário (-8mm) é direcionado para quatro

[2]ROM - material extraído da frente de lavra da mina e destinado à planta de beneficiamento mineral.

[3]*Underflow* é o fluxo de material composto pelas partículas mais finas que passam por um processo de peneira-

classificadores espirais. Nestes equipamentos é realizado a seleção de granulometria adequada a ser alimentada na etapa de concentração magnética (-0,5mm). O material retido nos classificadores espirais (-8mm, +0,5mm) é direcionado para as peneiras desaguadoras, sendo que nestas peneiras o fluxo de *overflow* [4] é empilhado como produto (*Sinter-feed* [5]), e o *underflow* é adicionado ao material passante dos classificadores e direcionado para o tanque de alimentação da etapa de concentração magnética.

2.1.2. O Circuito de Concentração Magnética de Mina Fábrica

A concentração magnética de minérios de baixo teor de ferro demanda circuitos otimizados que possibilitem o alcance dos melhores teores possíveis de concentrado, mantendo o custo de beneficiamento o mais baixo possível.

Os circuitos de separação magnética são classificados, basicamente, de duas formas: (i) circuitos de separação de grossos e (ii) circuito de separação de finos. A classificação, portanto, depende da granulometria do material que alimenta o equipamento.

O circuito de separação magnética de finos, como o de Mina Fábrica, opera com particulas alimentadas com granulometria inferior a 0,5 mm. Esta configuração pode ser utilizada para diversos objetivos distintos, como produção direta de *pellet-feed*, etapa de pré-concentrado de flotação reversa ou etapa de redução de teor no rejeito de flotação reversa. A Figura 2.2 apresenta a configuração do circuito de concentração magnética de finos existente em Mina Fábrica.

mento ou classificação granulométrica.

[4] *Overflow* é o fluxo de material composto pelas partículas mais grossas que passam por um processo de peneiramento ou classificação granulométrica.

[5] *Sinter-feed* é o produto de fração fina mais utilizado nas siderúrgicas. A granulometria deste produto varia entre 0,5mm e cerca de 1,0 a 1,2mm.

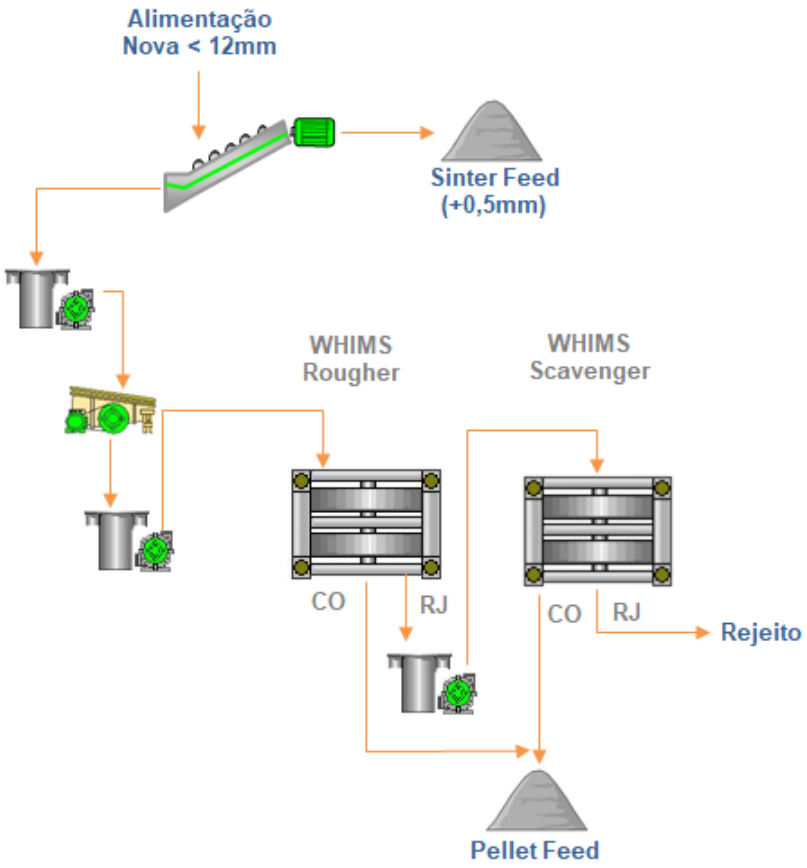

Figura 2.2: Diagrama do circuito de concentração magnética de finos de Mina Fábrica. Fonte: Marques (2020)

A definição do número de estágios do circuito de separação de finos, bem como as configurações dos mesmos, é feita com base nos resultados de caracterização mineral. De acordo com a Figura 2.2, no caso da concentração magnética de Mina Fábrica são utilizados dois conjuntos de concentradores magnéticos formando um estágio *Rougher*[6]/*Scavenger*[7]. Neste tipo de circuito, o produto do primeiro conjunto de concentradores (*Rougher*) já é considerado produto desta etapa, ao passo que os fluxos de médio e rejeito (conforme serão detalhados na próxima seção) são direcionados para o segundo conjunto de concentradores (*Scavenger*). O produto deste segundo estágio de concentração também é considerado o produto do processo de concentração magnética, já os fluxos de médio e rejeito são direcionados para o espessador de rejeitos da usina de beneficiamento.

[6]*Rougher* é o primeiro estágio de beneficiamento mineral, responsável pelo desbaste inicial, tem objetivo de recuperar o máximo possível do mineral de interesse, sem se ater tanto aos contaminantes presentes.

[7]*Scavenger* é o último estágio de beneficiamento mineral, responsável por recuperar o máximo possível do mineral de interesse que está sendo direcionado para o rejeito.

2.1.3. Concentrador Magnético de Mina Fábrica

Os concentradores magnéticos de Mina Fábrica são do tipo *Wet High Intensity Magnetic Separator* (WHIMS), constituídos por conjuntos de eletroímas, sistemas de tração, eixo e discos de rotores que possuem matrízes magnéticas em suas extremidades, conforme demonstrado pela Figura 2.3.

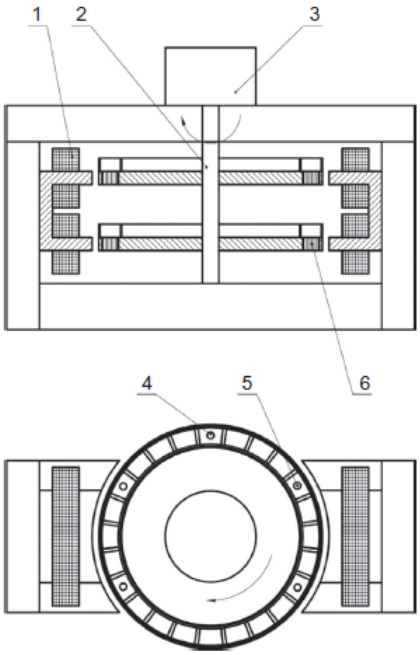

Figura 2.3: Concentrador magnético - Jones. (1) Eletroímas, (2) Eixo, (3) Sistema de tração, (4) Fluxo de concentrado, (5) Fluxo de alimentação, (6) Matriz magnética. Fonte: Xiong e Holmes (2015)

Quando uma corrente elétrica é aplicada nas bobinas dos eletroímas, um campo elétrico de alta intensidade com alto gradiente é produzido na zona de separação do equipamento, com maior intensidade na parte superior dos dentes das placas ranhuradas das matrizes magnéticas, alcançando até 2T. A Figura 2.4 apresenta as ranhuras existentes nas matrizes magnéticas.

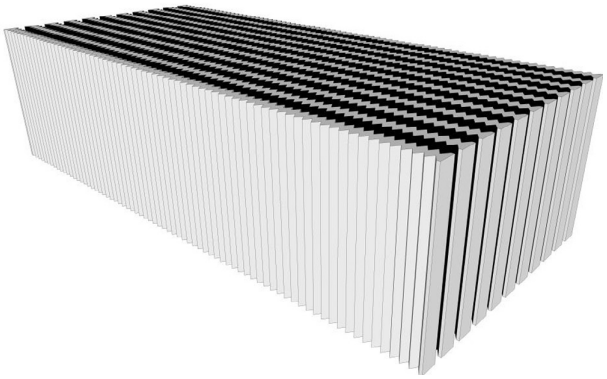

Figura 2.4: Exemplo de matriz magnética. Fonte: Ge *et al.* (2017)

A separação ocorre dentro das matrizes que estão na extremidade dos discos dos rotores. A primeira etapa do processo é a alimentação da polpa nas matrizes, fazendo com que a polpa atravesse a região de campo magnético de alta intensidade. Esta etapa de alimentação é contínua, devido à rotação dos discos, e ocorre no início da região permeada pelo campo magnético. As partículas magnéticas são captadas e permanecem retidas entre as ranhuras das matrizes magnéticas, já as partículas sem características magnéticas passam diretamente pelas matrizes, sendo direcionadas para o fluxo de rejeito. Com o giro do disco, as matrizes atingem a região do fluxo de lavagem dos médios, o qual é composto por jatos de sprays fixos, com pressão ajustada com a finalidade de retirar as partículas com baixa característica magnética e as partículas de *ganga* que não foram direcionadas no fluxo de rejeito. Na sequência do giro do disco, as matrizes atingem a região do fluxo de concentrado, que também é composto por jatos de sprays fixos com pressão, normalmente, superior àquela do fluxo dos médios. A Figura 2.5 demonstra a sequência de etapas descritas.

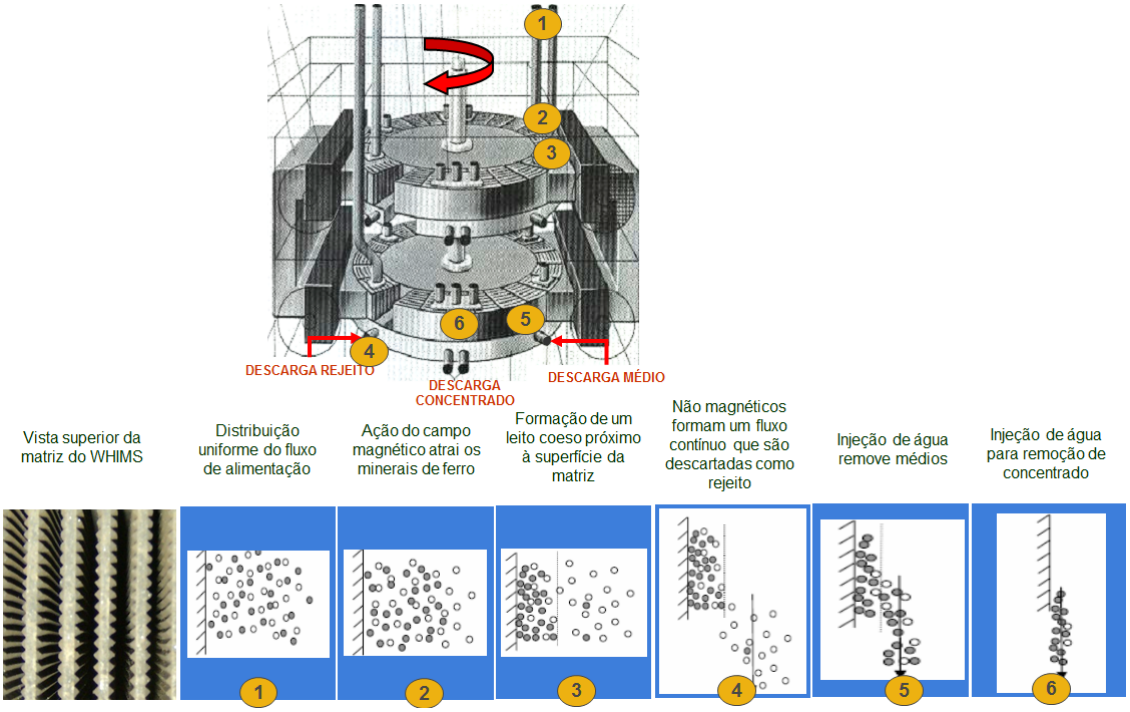

Figura 2.5: Esquema sequencial de funcionamento do concentrador WHIMS. Fonte: Marques (2020)

O fluxo de concentrado do primeiro conjunto de concentradores magnéticos (*Rougher*), em conjunto com o fluxo de concentrado do segundo conjunto de concentradores magnéticos (*Scavenger*) compõem o produto da etapa de concentração magnética de Mina Fábrica, sendo direcionado, como *Pellet-feed*, para a etapa de Pelotização.

2.1.4. Benefícios do Trabalho na Concentração Magnética

Como apresentado na seção anterior, durante as etapas do processo de beneficiamento da Usina de Concentração de Mina Fábrica, o material é preparado - cominuído, lavado, peneirado e classificado - para que seja alimentado na etapa de concentração magnética. Assim, é garantindo que os requisitos de percentual de sólidos, densidade e granulometria estejam dentro dos limites para a devida operação desta etapa. No entanto, como apresentado por Chen *et al.* (2008), através da Equação (2.1), a eficiência de um processo de concentração magnética E depende do teor do material alimentado.

$$E = R\left[1 - \frac{f(c_m - c)}{c(c_m - f)}\right], \tag{2.1}$$

onde R é a recuperação metalúrgica, c é o teor de ferro no concentrado, f o teor no material alimentado, e c_m é o teor máximo de ferro da hematita (70% Fe).

Além disso, como apresentado em Val (2014), o controle dos concentradores magnéticos de Mina Fábrica é realizado através do ajuste do campo magnético e da adição de água de médio e concentrado dos equipamentos, ajustes estes que são realizados em função do teor de ferro e sílica do material alimentado na etapa de concentração magnética. Considerando que atualmente a informação do teor do material alimentado na etapa de concentração magnética só é obtido, via análise laboratorial, horas após a amostragem, os ajustes descritos são realizados baseado no último valor obtido da análise laboratorial, ou seja, do material alimentado cerca de duas horas atrás. Neste cenário, torna-se de extrema relevância a informação da predição do teor do minério alimentado no próprio instante dos ajustes, ou mesmo a informação de tendência ascendente ou descendente destes teores.

Outra contribuição importante deste trabalho é na prevenção do entupimento das matrizes magnéticas. Caso o material alimentado possua alto percentual de partículas magnéticas, consequentemente um teor mais elevado de %Fe, e o ajuste do campo magnético dos eletroímas esteja em um valor mais elevado, pode ocasionar no entupimento das matrizes magnéticas . Este entupimento, como exemplificado na Figura 2.6, impacta excessivamente o desempenho do circuito de separação magnética.

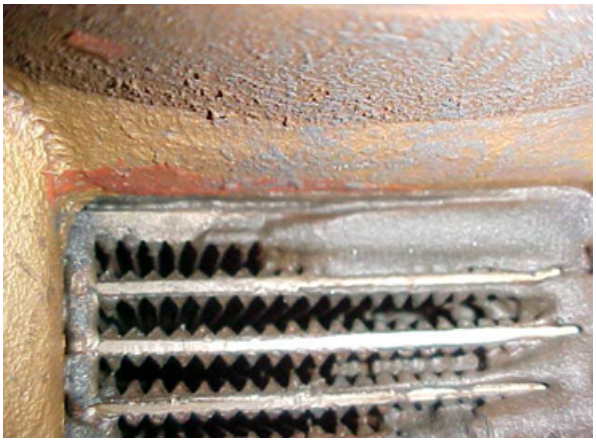

Figura 2.6: Exemplo de matriz magnética entupida. Fonte: Marques (2020)

2.2. Flotação

O processo mineral que explora as diferenças de afinidades dos componentes presentes na polpa de minério, com o ar e com a água, promovendo assim a separação destes, é conhecido como flotação. A separação destes componentes ocorre em meio aquoso, com auxílio de reagentes específicos, que modificam a superfície das partículas, aumentando a afinidade do ferro e da sílica, para a água e as bolhas de ar, respectivamente. Como apresentado por Marques (2016), a seletividade dos diferentes componentes baseia-se no fato de que suas superfícies apresentam diferentes afinidades químicas com a água. Quanto maior a afinidade do material com a água, ou quanto maior sua capacidade de ser molhada, mais hidrofílica é a superfície do mineral, por outro lado, quanto menor esta capacidade, mais hidrofóbica é a superfície.

2.2.1. Etapas de pré-processamento

A Figura 2.7 representa o fluxograma das etapas do processo de beneficiamento mineral da ITMI de Vargem Grande.

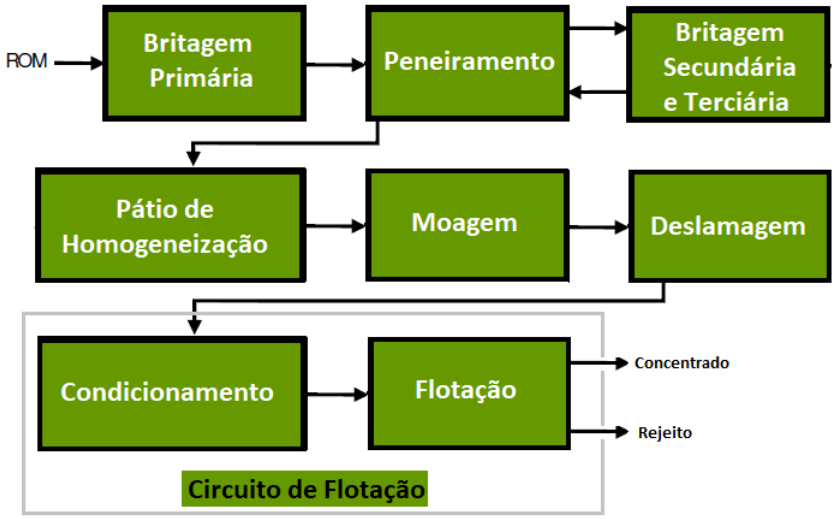

Figura 2.7: Fluxograma de etapas do processo de beneficiamento mineral da ITMI de Vargem Grande. Fonte: Elaborada pelo autor

O ROM é transportado até o britador primário através de caminhões (fora-de-estrada). A etapa de britagem primária, primeiro processo de cominuição da planta de beneficiamento da ITMI de Vargem Grande, é realizada por um britador de mandíbula, que reduz a granulometria do material para valores inferiores a 300mm. Após a britagem primária, o material é descarregado em uma pilha pulmão (capacidade de 15.000 t) que é utilizada para garantir uma taxa média de transporte do material até a etapa de peneiramento.

A etapa de peneiramento inicia-se em um silo, que possui um conjunto de 16 alimentadores que transportam o material para um conjunto de 16 peneiras vibratórias. Os peneiramentos secundário, terciário e quaternário são realizados em um único estágio nas peneiras vibratórias que possuem 02 decks.

Conforme apresentado pela Figura 2.8, o material retido no primeiro deck de peneiramento (-300mm, +32mm) é destinado à alimentação das britagens secundária e terciária. O material retido no segundo deck de peneiramento (-32mm, +12mm) é destinado à alimentação da britagem quaternária. Já o *underflow* da etapa de peneiramento (-12mm) é direcionado ao pátio de homogeneização.

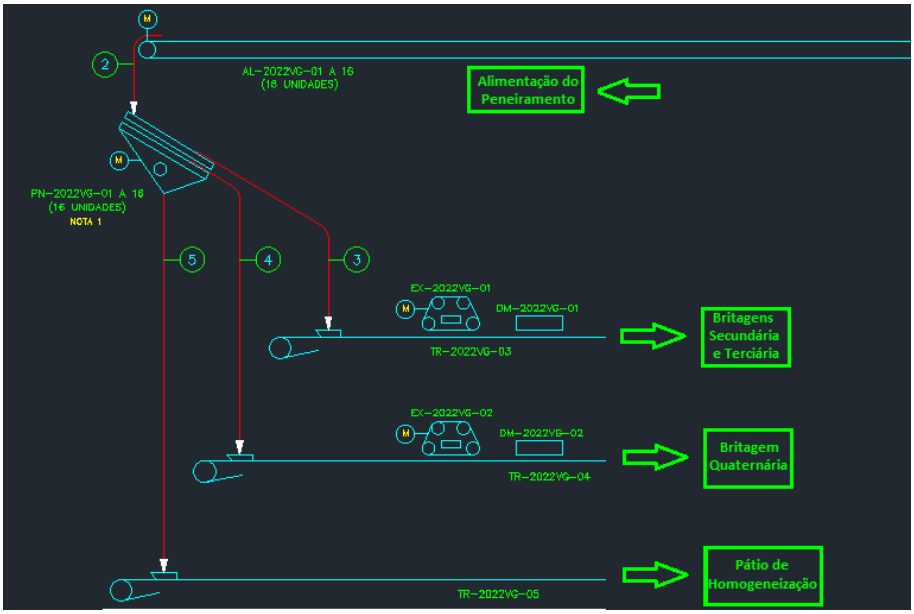

Figura 2.8: Diagrama do peneiramento da ITMI de Vargem Grande. Fonte: Minerconsult (2012)

Através de uma empilhadeira, o material é empilhado em dois pátios paralelos, com capacidade de aproximadamente 140.000 toneladas, de forma planejada e definida pelas equipes de geologia. O pátio de homogeneização é utilizado para possibilitar que a retomada do material, a ser alimentado nas próximas etapas, não apresente grandes variações instantâneas, atuando como um filtro que reduz boa parte das variabilidades provenientes das frentes de lavra.

O material retomado do pátio de homogeneização é transpotado até a etapa de moagem da usina da ITMI de Vargem Grande. Alimentadores controlam a vazão do material de saída do silo (valor projetado de aproximadamente 3100 t/h), que é enviado para a moagem primária. Os teores aproximados esperados nesse fluxo de alimentação da moagem são de 44,0% e 35,8%, para %ferro e %sílica, respectivamente. Após a etapa de moagem primária, o material (-3mm) é encaminhado para a classificação, que neste processo é realizada através de bateria de ciclones. O *overflow* desta primeira etapa de classificação (-0,15mm) é direcionado para o processo de deslamagem, já o *underflow* (-3mm, +0,15mm) é destinado à segunda etapa de moagem. Após a segunda etapa de moagem, o *overflow* (-0,15mm) também é direcionado para o processo de deslamagem, já o *underflow* (-1mm, +0,15mm) é recirculado na segunda etapa de moagem.

O processo de deslamagem da ITMI de Vargem grande é realizado através de três etapas, cada uma delas composta por quatro baterias de ciclone. O objetivo deste processo é separar o material de interesse, contendo os finos de minério de ferro, dos finos que são compostos, em sua maioria, por lama. O *overflow* desta etapa é destinado ao espessador de lamas, no qual será realizado o tratamento para o reaproveitamento de água e a separação do rejeito, a ser depositado na barragem de rejeitos de Vargem Grande. Já o *underflow* desta etapa, contendo os finos de minério de ferro com as especificações necessárias, é destinado ao circuito de flotação reversa da ITMI de Vargem Grande.

2.2.2. O Circuito de Flotação Reversa da ITMI de Vargem Grande

Os circuitos de flotação reversa são projetados de acordo com o tipo de material a ser processado (considerando-se as informações dos estudos geológicos), os percentuais de ferro e sílica a serem obtidos no concentrado, as taxas de recuperação mássica e metalúrgica necessárias e os teores médios do material proveniente da frente de lavra.

O circuito de flotação reversa da ITMI de Vargem Grande é formado por duas etapas de condicionamento, nas quais são adicionados os reagentes à polpa de minério que será flotada no circuito. Os reagentes e suas respectivas funções são:

- Amido gelatinizado: agente depressor que tem a função de elevar a afinidade das moléculas de ferro com a água. É adicionado na primeira etapa de condicionamento do circuito de flotação e possui um tempo ideal de reação de cerca de 15 minutos;

- Soda cáustica: agente regulador que tem a função de adequar o pH da polpa para favorecer a eficiência dos agentes depressores e coletores. É adicionada na segunda etapa de condicionamento e visa manter o pH em torno de 10,5;

- Amina: agente coletor que por ser um polímero de cabeça polar positiva, adere-se à sílica, tornando-a hidrofóbica. Quando o fluxo de ar é adicionado ao sistema, bolhas serão formadas, carregando a sílica que está envolvida pela amina para a parte superior da célula. A amina também desempenha uma função espumante, quando em pH dentro da faixa ideal ($\approx$ 10,5), criando uma camada de espuma que mantém a sílica flutuando até ser retirada por transbordo. É adicionada no circuito logo após a segunda etapa de condicionamento.

A flotação reversa da ITMI de Vargem Grande é realizada em duas linhas paralelas, contendo cada uma cinco estágios distintos de flotação: *Rogher, Cleaner, Recleaner, Scavenger 1 e Scavenger 2*.

- *Rougher* é a primeira etapa da flotação, produz um concentrado que é direcionado para a etapa *cleaner* e um rejeito para a etapa *scavenger*;

- *Cleaner* é a segunda etapa da flotação, onde se atinje o teor de ferro desejado no concentrado. No circuito de flotação em questão, o concentrado desta etapa é direcionado para o estágio *recleaner* e o rejeito para a etapa *scavenger*;

- *Recleaner* é a terceira etapa da flotação, ou última etapa de limpeza do concentrado. Nesta etapa é realizado o ajuste do teor de sílica no produto final. O concentrado obtido neste estágio já é o produto final do circuito de flotação. O rejeito desta etapa é direcionado para a etapa *scavenger*;

- *Scavenger* é a etapa de recuperação do ferro que não foi direcionado para o concentrado final. No caso do circuito de flotação da ITMI de Vargem Grande, esta etapa é formada

por dois estágios, o concentrado é recirculado na etapa *rougher* e o rejeito é direcionado para o espessador de rejeitos.

Todos os estágios são formados por células do tipo tanque (*Tank Cell*). A Figura 2.9 representa o circuito da flotação reversa da ITMI de Vargem Grande.

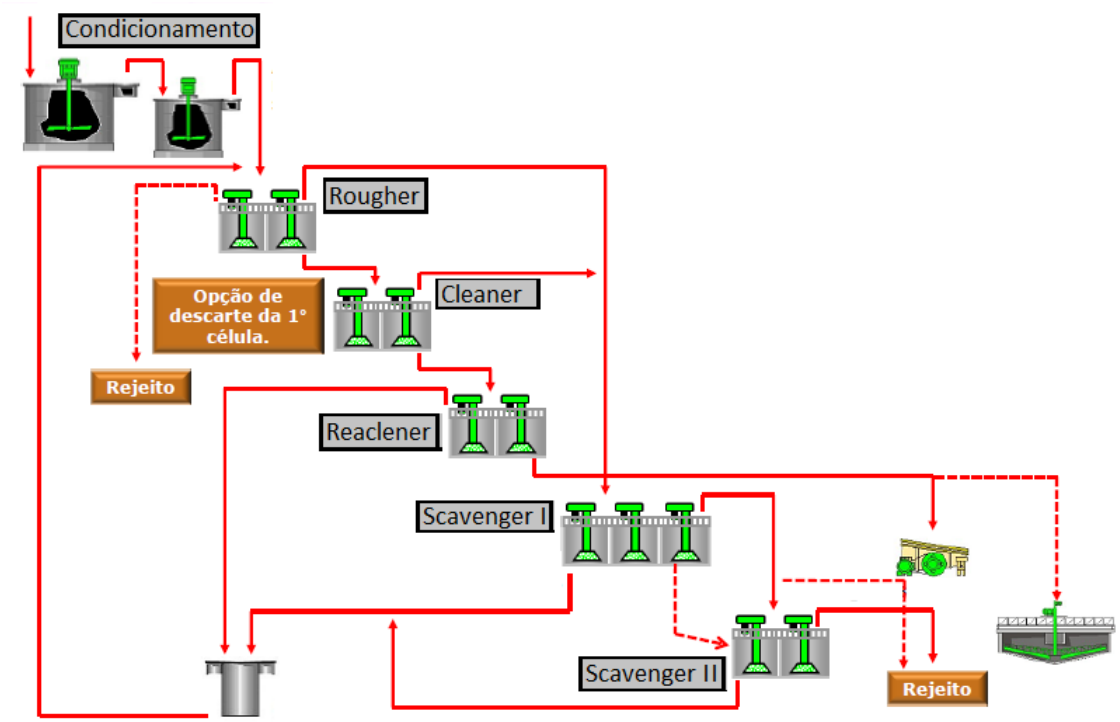

Figura 2.9: Diagrama do circuito de flotação reversa da ITMI de Vargem Grande. Fonte: Saborido (2014)

2.2.3. Células de Flotação (*Tank Cell*)

Os tanques de flotação da ITMI de Vargem Grande são do tipo *tankcell*. Como apresentado por Anderson (2017), embora existam diferentes tipos de equipamentos de flotação, cada um com um *design* distinto, a função primária de todos eles é garantir a necessária dispersão das partículas da polpa de minério. Com essa separação, busca-se assegurar que as partículas de sílica tornem-se suficientemente hidrofóbicas, levando-as a aderir à superfície das bolhas de ar, permitindo que sejam carregadas para a superfície do equipamento, onde será formada a espuma a ser retirada para o rejeito. Como apresentado por Marques (2016), para atingir esta funcionalidade, os equipamentos precisam atender as seguintes características:

- manter as partículas minerais em suspenção;
- produzir bolhas de ar suficientes e dispersa-las;

- garantir que todas as partículas tenham a mesma oportunidade de contato com as bolhas de ar;
- evitar formação de espaço morto;
- transportar o mineral de interesse (no caso o minério de ferro);
- reduzir ao máximo a turbulência na interface polpa/espuma;
- permitir a drenagem eficiente da espuma.

A Figura 2.10 representa o funcionamento das células de flotação do tipo *tankcell*. A polpa é alimentada na parte inferior do equipamento, entrando imediatamente na zona de circulação de polpa, evitando que sejam criadas zonas mortas. A agitação e disperção do ar é realizada pelo conjunto rotor/aerador. Na zona de separação é realizada a concentração do ferro, que é deprimido com o auxílio do amído, e separação da sílica, que se adere às bolhas, com o auxílio da amina. A flotação da sílica garante a formação da camada de espuma na superfície do tanque, sendo direcionada para a calha de rejeito. A polpa, contendo material com teor de ferro superior e teor de sílica inferior ao material alimentado, é direcionada para a saída de polpa.

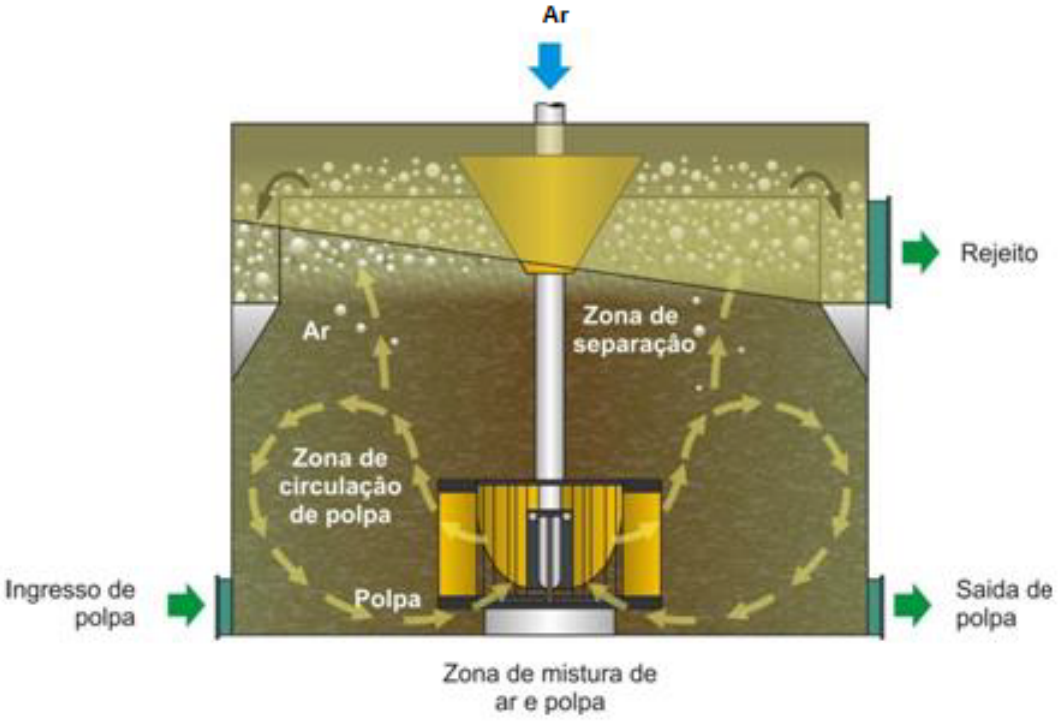

Figura 2.10: Representação de uma célula de flotação do tipo *Tankcell*. Fonte: Saborido (2014)

2.2.4. Benefícios do Trabalho na Flotação Reversa

Como apresentado no início deste capítulo, a flotação da sílica e a concentração do ferro ocorrem com o auxílio de reagentes específicos, que modificam a superfície de cada uma das

partículas. A dosagem destes reagentes depende diretamente do percentual de sólidos e dos teores ($\%Fe$ e $\%SiO_2$) alimentados no circuito de flotação. Outros ajustes, como nível da camada de espuma, tempo de residência do material e vazão alimentada são afetados pelas características do material. Neste contexto, torna-se de extrema relevância a informação da predição dos teores (ou mesmo a tendência ascendente ou descendente) do minério alimentado no circuito de flotação reversa no momento da realização de tais ajustes, uma vez que, como apresentado na Tabela 2.1, a dosagem descontrolada de reagentes pode trazer diversos efeitos indesejados.

Tabela 2.1: Efeitos de dosagem descontrolada de reagentes. Fonte Marques (2016)

Reagente	**Quantidade**	**Efeito**
Amido	Em falta	Espuma carregada de minerais de ferro e perda de recuperação
	Em excesso	Concentrado carregado de sílica
		Espuma "ensaboada"que gera instabilidade na formação de bolhas, impactando na obtenção de espessura ideal da espuma
Amina	Em falta	Dificuldade de obtenção do teor de sílica no concentrado
	Em excesso	Espuma carregada de minerais de ferro e perda de recuperação
Soda Cáustica (NaOH)	Em falta	A amina torna-se mais coletora, provocando espumação deficiente e bolhas quebradiças
	Em excesso	A amina amina torna-se mais espumante, causando espumação excessiva, porém, com pouco teor de sílica

Conforme demonstrado, a informação dos teores de ferro e sílica alimentados no processo de flotação são de extrema importância e contribuem efetivamente para a otimização dos controles deste processo. A ITMI de Vargem Grande foi escolhida por apresentar um processo de concentração mineral importante e por permitir o historiamento dos valores das amostras de laboratório em uma frequência de amostragem semelhante à obtida na concentração magnética da Mina de Fábrica. Porém, a ITMI de Vargem Grande possui um equipamento amostrador de fluxos *online*. Este equipamento permite que amostras dos teores dos respectivos fluxos sejam fornecidas em frequências de minutos, o que garante a adequada informação para a parametrização dos controles do circuito de flotação. No entanto, o trabalho apresentado pode ser utilizado em outras instalações de beneficiamento de minério de ferro semelhante, que não possuam amostradores de fluxos *online*, sendo esta condição a mais comumente encontrada nas plantas de beneficiamento mineral do Brasil.

3. Material e Métodos

No decorrer do desenvolvimento deste trabalho foram utilizados sistemas já disponíveis no ambiente de automação das instalações de beneficiamento descritas no capítulo anterior. A coleta e tratamento dos dados foi realizada por meio de ferramentas existentes nos próprios sistemas de automação das instalações em questão. As etapas de análises, elaboração de algoritmos, testes e validação dos modelos foram realizadas no ambiente do MATLAB. Já a implementação, visando a validação com dados reais e a disponibilização da solução proposta para utilização pelas equipes de processo e automação, foi realizada no software *Labview* [1], já existente em algumas instalações produtivas da Vale. Nesta seção serão detalhados tais sistemas e as atividades desenvolvidas durante cada uma das etapas, que propiciaram os resultados e análises que serão apresentados nos Capítulos 4 e 5.

3.1. Arquitetura dos Sistemas de Automação

Como apresentado anteriormente, as plantas de beneficiamento mineral utilizadas no desenvolvimento deste estudo são a Usina de Beneficiamento de Mina Fábrica e a Usina da ITMI de Vargem Grande. Cada uma dessas plantas possui não só um processo de beneficiamento distinto (concentração magnética e flotação reversa para Mina de Fábrica e ITMI de Vargem Grande, respectivamente), como também possuem arquiteturas de sistema de automação diferentes. Nas seções a seguir serão apresentadas, resumidamente, ambas arquiteturas.

Durante a execução deste trabalho, foi realizado um projeto de substituição dos sistemas PIMS nas instalações industriais da Vale em Minas Gerais. Esta substituição afeta diretamente o trabalho em questão, visto que a interface de leitura dos dados é implementada através do sistema PIMS. No inicio deste trabalho, quando foram realizadas as atividades de levantamento das informações e coleta de dados, o fabricante e a arquitetura do sistema PIMS era da forma descrita nas Seções 3.1.1 e 3.1.2. As ferramentas utilizadas na coleta dos dados faziam parte do pacote de aplicações do sistema PIMS que foi substituído. Ao final deste trabalho, quando da implementação prática da solução proposta, o fabricante e a arquitetura do sistema PIMS já haviam sido trocados, passando a ser da forma apresentada na Seção 3.1.3. A implementação, utilizando esta nova arquitetura, será apresentada no Capítulo 5.

3.1.1. Arquitetura do sistema de automação de Mina de Fábrica

O sistema de automação da Mina de Fábrica é formado por Controladores Lógicos Programáveis (CLPs) da família Controllogix do fabricante Allen-Bradley Rockwell. O Sistema de Supervisão e Aquisição de Dados (SCADA) é o *Factory-Talk View*, do mesmo fabricante, e possui arquitetura cliente-servidor, com par de servidores redundantes. A rede de instrumentação

[1] *Labview* é uma plataforma de design de sistema e um ambiente de desenvolvimento baseado em linguagem gráfica da *National Instruments*.

segue o padrão 4 a 20mA, já a rede controle segue o padrão Ethernet, com protocolo Ethernet-ip, utiliza switchs gerenciaveis Stratix e IE-3000 (ambos possuem *hardware* Cisco). A rede de supervisão (Rede TA) também segue o padrão Ethernet, porém, com protocolo TCP/IP.

O sistema de historiamento PIMS era o InfoPlus 21, do fabricante AspenTech[2]. A coleta dos dados de processo era realizada por meio de dois coletores da arquitetura do PIMS, por meio de servidores OPC do fabricante KepServer. Os coletores operavam em redundância ativo-ativo, realizando a coleta, e o servidor do PIMS definia qual seria utilizado para a obtenção dos dados. A interface de comunicação com os dados de laboratório era realizada atráves da leitura dos dados exportados pelo sistema *Laboratory Information Management System* (LIMS) Nautilus, do fabricante Thermo Fisher. Após realizar a coleta dos dados, o sistema PIMS armazenava as informações em bancos de dados temporais proprietários. O acesso dos usuários às informações disponibilizadas pelo sistema PIMS, era realizado através das ferramentas disponibilizadas pela solução da AspenTech, através da Rede TI, que possuia interface com a Rede TA através de *Firewalls*. É também através da Rede TI que é feita a leitura das informações para os sistemas *Enterprise Resource Planning* (ERP). A Figura 3.1 representa o diagrama da arquitetura do sistema PIMS antes da substituição.

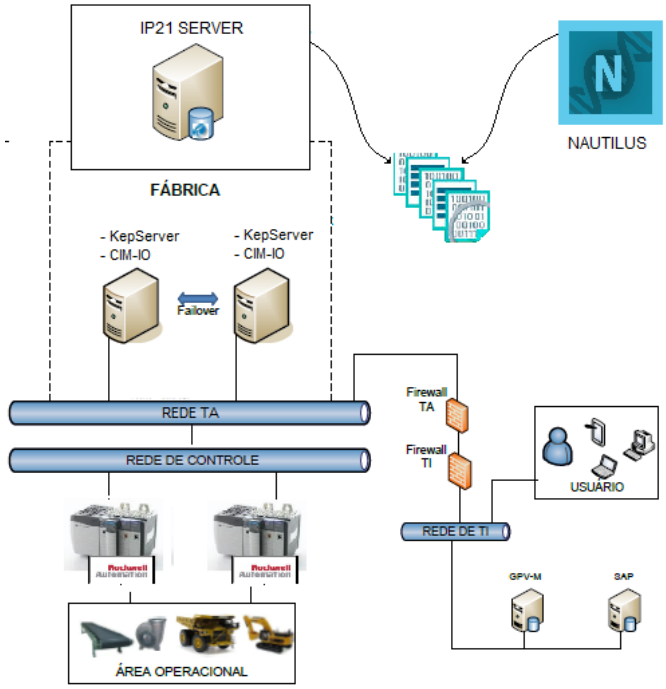

Figura 3.1: Diagrama da arquitetura do sistema PIMS. Fonte: elaborada pelo autor

[2]O sistema da AspenTech foi substituído, durante o desenvolvimento deste trabalho, pelo sistema PI da fabricante OSI Software.

3.1.2. Arquitetura do sistema de automação da ITMI de Vargem Grande

O sistema de automação da ITMI de Vargem Grande é do tipo Sistema Digital de Controle Distribuído (SDCD), do fabricante Schneider Electric. É formado por CLPs M580 da família Modicon e interface de supervisão Vijeo Citect. A arquitetura é cliente-servidor, com par de servidores redundantes. A rede de instrumentação segue o padrão Profibus PA, já a rede controle segue o padrão Ethernet, com protocolo Modbus/TCP, e utiliza switchs gerenciaveis ConneXium, também do fabricante Schneider Electric. A rede de supervisão (Rede TA) também segue o padrão Ethernet, porém, com protocolo TCP/IP, através de switchs gerenciaveis RuggedCom.

O sistema de historiamento PIMS, assim como na arquitetura da Mina de Fábrica, era o InfoPlus 21 do fabricante AspenTech[3]. A arquitetura do sistema PIMS, bem como a interface com o sistema LIMS, seguia o mesmo padrão apresentado para a Mina de Fábrica e exemplificado na Figura 3.1.

3.1.3. Nova arquitetura do sistema PIMS

O sistema PIMS InfoPlus 21 do fabricante AspenTech foi substituido pelo sistema PIMS PI do fabricante OSI Software. Essa substituição foi realizada com objetivo não só de centralizar a gestão e governança dos sistemas PIMS na unidades da Vale em Minas Gerais, mas também com objetivo de padronizar todo o parque de ativos. Nesta nova topologia, todos os servidores do Infoplus 21, que eram distribuídos, foram substituídos por dois servidores do PI. Estes dois novos servidores redundantes são hospedados em ambiente de virtualização e possuem, dessa forma, dois níveis de redundância. O primeiro nível de redundância é o da própria aplicação, através de *High Availability* (HA), o segundo é a redundância de host, garantida pelo ambiente de virtualização. Diversas outras ferramentas do PI da OSI Software passaram a estar disponíveis para todas as unidades da Vale em Minas Gerais, porém, não fazem parte do escopo deste trabalho. A Figura 3.2 representa a nova arquitetura do sistema PIMS que atende tanto a Mina de Fábrica, quanto a ITMI de Vargem Grande.

[3]Este sistema também foi substituído, durante o desenvolvimento deste trabalho, pelo sistema PI da fabricante OSI Software.

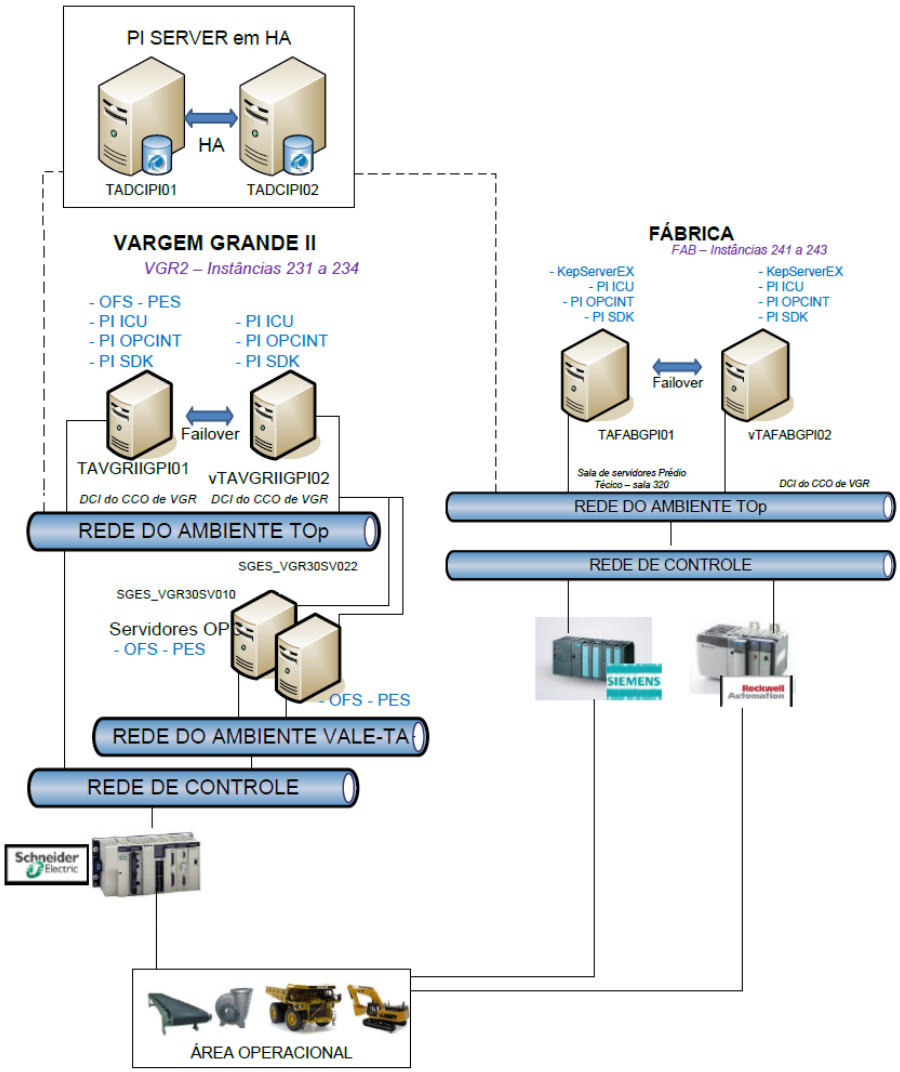

Figura 3.2: Diagrama da nova arquitetura do sistema PIMS centralizado. Fonte: elaborada pelo autor

3.2. Coleta e tratamento dos dados

Dentre as diversas ferramentas de interface do sistema PIMS, a interface do SQLPlus foi a escolhida para possibilitar a obtenção das informações históricas dos teores dos materiais alimentados na etapa de concentração magnética de Mina Fábrica e na epata de flotação reversa da ITMI de Vargem Grande. O período de coleta inicialmente considerado, para este trabalho, foi de primeiro de janeiro de 2018 até 25 de fevereiro de 2019.

3.2.1. Dados da Concentração Magnética

Para os dados da concentração magnética de Mina Fábrica, foi desenvolvida uma consulta SQL (considerando as funções próprias do SQLPlus) que possibilitasse a obtenção dos dados de duas formas distintas:

- Considerando apenas as amostras dos teores existentes na base de dados do PIMS. Ou seja, caso existam amostras faltantes (por algum problema na amostragem de laboratório, ou do próprio sistema de automação), a diferença entre *timestamp* de duas amostras sequenciais irá apresentar valores múltiplos de 2 horas;

- Considerando a interpolação de dados com o *timestamp* base de 2 horas, neste caso, caso aja alguma amostra de teores faltante, ela será substituída pelo dado linearmente interpolado.

A consulta realizada considerou não apenas os dados dos teores amostrados via laboratório, mas também outras informações do processo de concentração magnética que pudessem ser utilizados em futuras análises. Porém, neste trabalho, são utilizadas apenas as informações dos teores de ferro e sílica no material alimentado. Como apenas as informações dos teores possuem taxa de amostragem de 2 horas (em função do tempo de processamento no laboratório), as demais informações da concentração magnética foram obtidas considerando a média dos valores registrados nas últimas 2 horas, conforme:

- Teor de ferro do material alimentado na concentração magnética - considerando as amostras efetivamente registradas no banco de dados, ou através da interpolação linear dos dados;

- Teor de sílica do material alimentado na concentração magnética - considerando as amostras efetivamente registradas no banco de dados, ou através da interpolação linear dos dados;

- Teor de ferro do concentrado (produto da etapa de concentração magnética) - considerando as amostras efetivamente registradas no banco de dados, ou através da interpolação linear dos dados;

- Teor de sílica do concentrado (produto da etapa de concentração magnética) - considerando as amostras efetivamente registradas no banco de dados, ou através da interpolação linear dos dados;

- Taxa de vazão do material alimentado na concentração magnética - média dos valores obtidos nas últimas 2 horas;

- Densidade do material alimentado na concentração magnética - média dos valores obtidos nas últimas 2 horas;

- Valor de corrente do eletroímas dos concentradores magnéticos - média dos valores obtidos nas últimas 2 horas - 2 conjuntos de eletroímas para cada concentrador magnético (totalizando 4 valores);

- Pressão da água de médio - média dos valores obtidos nas últimas 2 horas - 1 valor para cada concentrador magnético;

- Pressão da água de concentrado - média dos valores obtidos nas últimas 2 horas - 1 valor para cada concentrador magnético;

Inicialmente, foram criadas tabelas temporárias para cada uma das variáveis apresentadas, seguindo as formas de consulta apresentada para cada uma delas. Posteriormente, foi criada uma tabela única, concatenando todas as tabelas temporárias, através da junção *inner join*, considerando o *timestamp* de cada uma das tabelas temporárias como o parâmetro de concatenação.

A base de dados adquirida, compreendendo cerca de 14 meses, foi inicialmente analisada e, considerando a quantidade de dados faltantes de amostras (por problemas de análise laboratorial ou por falhas no sistema de historiamento), optou-se por trabalhar com os dados registrados durante o mês de setembro de 2018. Neste excerto, considerando-se apenas os dados amostrados, totalizam-se 320 amostras, já, considerando também os dados interpolados, totalizam-se 360 amostras. O Apêndice A apresenta a consulta realizada nos dados do PIMS da concentração magnética.

Os dados obtidos através da metodologia apresentada constituem importante fonte de informação para as análises e desenvolvimentos a serem apresentados nas próximas seções, bem como para futuros outros trabalhos de otimização que possam vir a ser realizados, referentes ao processo da concentração magnética. As Figuras 3.3 e 3.4 representam o comportamento histórico do teor de ferro, respectivamente, amostrado e interpolado, na concentração magnética de Mina Fábrica. Já as Figuras 3.5 e 3.6 representam o comportamento histórico do teor de sílica amostrado e interpolado, respectivamente.

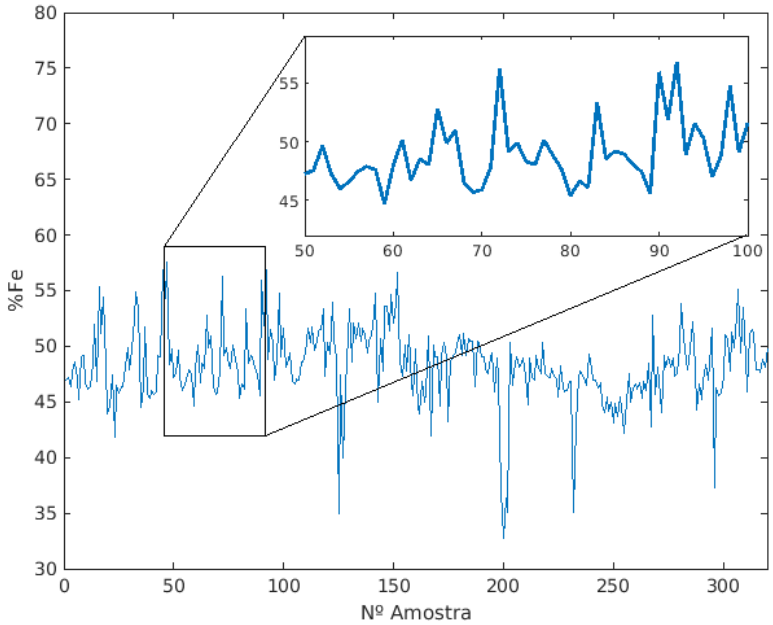

Figura 3.3: Comportamento histórico do teor de ferro (amostrado) na alimentação da concentração magnética. Fonte: elaborada pelo autor.

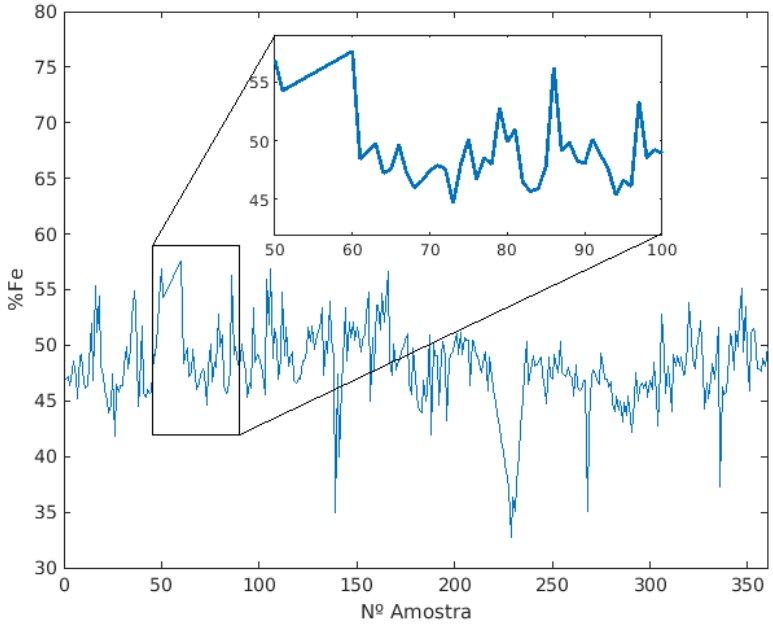

Figura 3.4: Comportamento histórico do teor de ferro (interpolado) na alimentação da concentração magnética. Fonte: elaborada pelo autor.

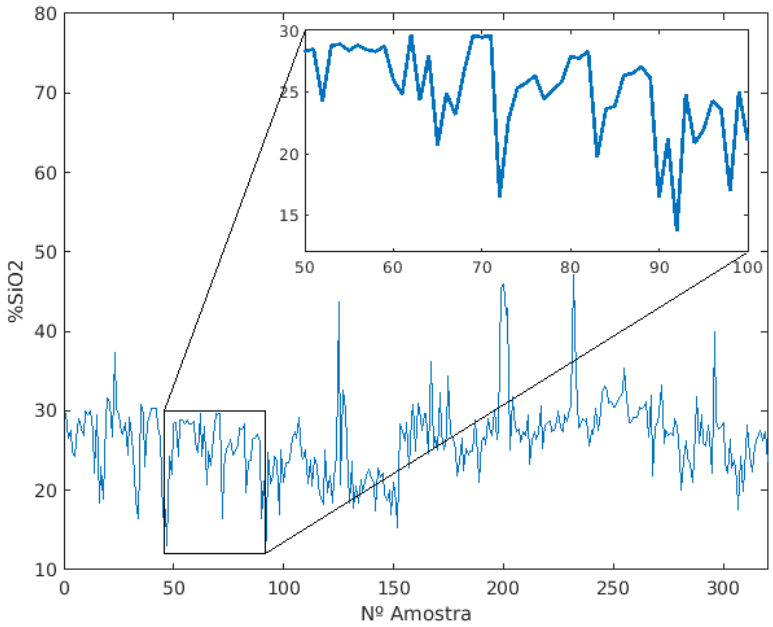

Figura 3.5: Comportamento histórico do teor de sílica (amostrado) na alimentação da concentração magnética. Fonte: elaborada pelo autor.

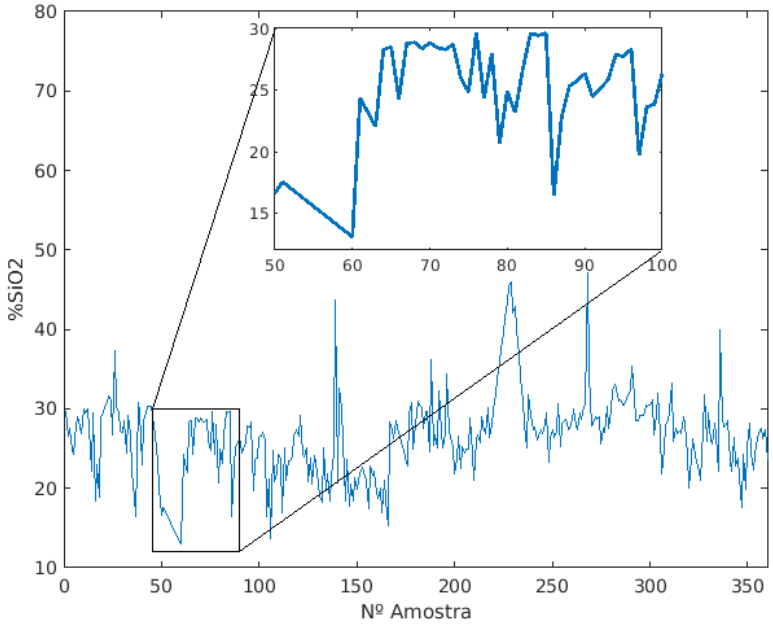

Figura 3.6: Comportamento histórico do teor de sílica (interpolado) na alimentação da concentração magnética. Fonte: elaborada pelo autor.

3.2.2. Dados da Flotação Reversa

Para obtenção dos dados da flotação reversa da ITMI de Vargem Grande, foi utilizada a mesma consulta SQL desenvolvida para a obtenção dos dados da concentração magnética da Mina de Fábrica. Foram realizadas algumas adequações que possibilitassem a execução da consulta no servidor do PIMS de Vargem Grande, como alteração dos nomes de servidor, de tabelas e dos próprios tags a serem coletados.

Diferentemente do que foi feito para a concentração magnética, neste caso, foram coletados apenas os dados referentes aos teores de ferro e sílica do material alimentado na flotação reversa, visto que o objetivo é validar o desenvolvimento realizado para o processo da concentração magnética em cenários semelhantes. Assim, como foi feito para os dados da concentração magnética, para a flotação reversa também foram adquiridos dados referentes a 14 meses de registros no PIMS.

Conforme definido na Seção 3.2.1, o registro para o mês de setembro de 2018, considerando-se apenas os dados amostrados, totalizaram 346 amostras. A Figura 3.7 representa o comportamento do teor de ferro amostrado na alimentação da flotação reversa da ITMI de Vargem Grande.

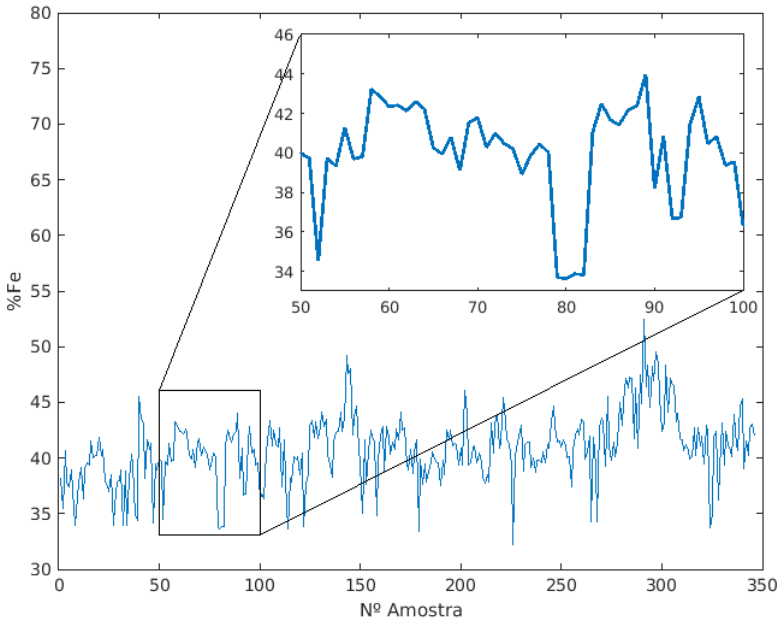

Figura 3.7: Comportamento histórico do teor de ferro (amostrado) na alimentação da flotação reversa. Fonte: elaborada pelo autor.

3.3. Estrutura Labview

Visando a implementação das soluções apresentadas neste trabalho, de forma a disponibilizar, para os engenheiros de processo e automação, as informações que possibilitem melhorias dos algoritimos de controle dos processos em questão, optou-se pela utilização da arquitetura distribuída do Labview.

A Gerência de Controle e Automação dos corredores Sul e Sudeste de Ferrosos da Vale S.A. possui uma arquitetura distribuida do Labview, projetada para implmentar soluções de otimização dos processos das instalações de beneficiamento mineral da empresa, no estado de Minas Gerais. Esta arquitetura é formada por um servidor virtualizado (*Virtual Machine*) hospedado no ambiente de virtualização localizado no *Datacenter* da unidade de Conceição, em Itabira - MG. A estrutura de virtualização permite que exista redundância do servidor do Labview através dos *hosts* em que o mesmo está hospedado, sendo que, nesta situação, caso ocorra falha em um dos *hosts* do ambiente, o próprio gerenciador da virtualização transfere o servidor virtualizado para outro. A estrutura do Labview conta, também, com diversos controladores industriais remotos, que são distribuídos em diversas instalações da empresa no estado de Minas Gerais. Estes controladores estão conectados diretamente às redes de controle de cada uma das instalações, possibilitando acesso direto aos CLPs, remotas, dentre outros. A Figura 3.8 representa a estrutura deste ambiente.

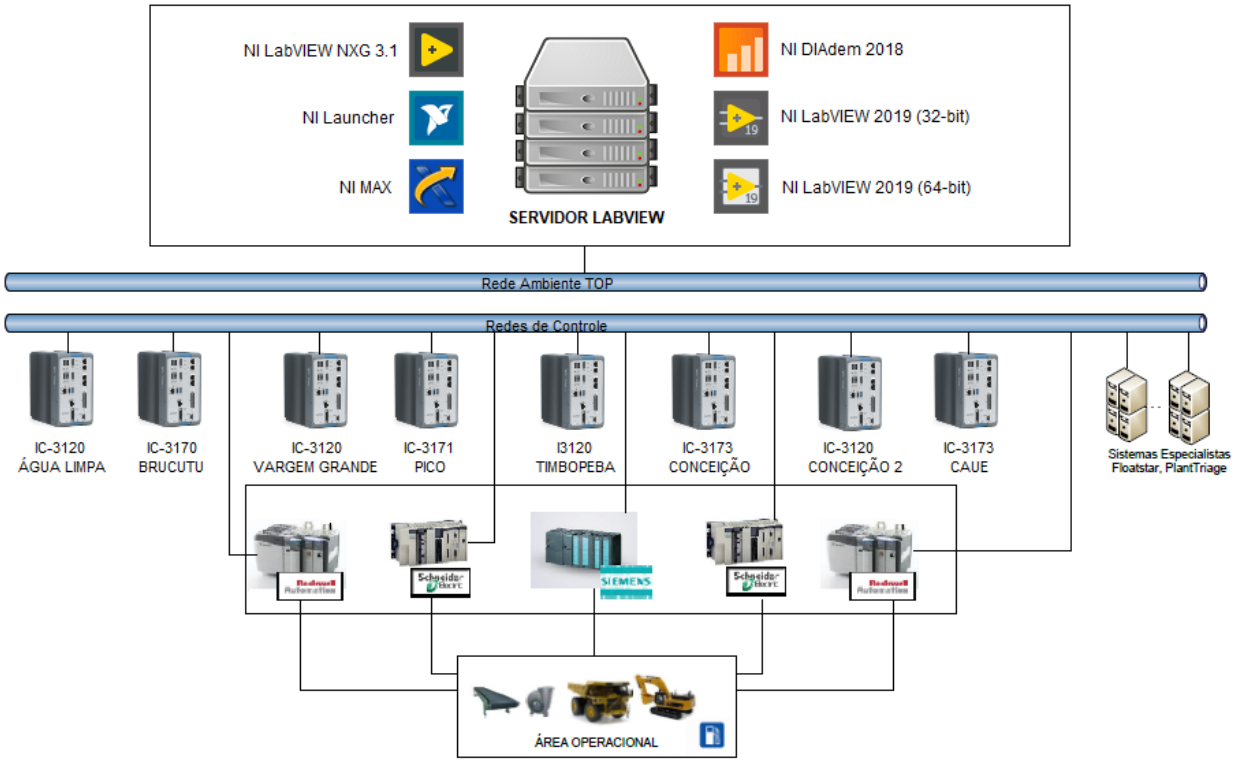

Figura 3.8: Representação da topologia do Sistema Labview da Gerência de Engenharia de Automação. Fonte: elaborada pelo autor.

4. Modelo Autorregressivo

Neste capítulo, serão apresentadas as análises realizadas nas bases de dados utilizadas nestre trabalho, bem como os resultados das predições dos teores de ferro e sílica dos processos de beneficiamento. Inicialmente, serão apresentados os desenvolvimentos teóricos utilizados em cada etapa do desenvolvimento. Em seguida, serão apresentados os resultados das análises para cada um dos cenários abordados neste trabalho. Esta sequência de desenvolvimento será utilizada para definir a estrutura do modelo e a ordem que será utilizada na predição dos teores. Ao fim do capítulo serão apresentados os resultados de predição dos teores, bem como o cenário mais indicado para realização da predição dos mesmos, se com dados amostrados ou interpolados.

Como demonstrado por Aguirre (2004), um modelo geral de série temporal pode ser representado por:

$$\begin{aligned} A(q)y(k) &= \frac{B(q)}{F(q)}u(k) + \frac{C(q)}{D(q)}v(k), \\ y(k) &= \frac{B(q)}{F(q)A(q)}u(k) + \frac{C(q)}{D(q)A(q)}v(k), \\ y(k) &= G(q)u(k) + H(q)v(k), \end{aligned} \tag{4.1}$$

sendo q^{-1} o operador de atraso, tal que $y(k)q^{-1} = y(k-1), v(k)$ representa o ruído branco. Os polinômios $A(q)$, $B(q)$, $C(q)$, $D(q)$ e $F(q)$ são definidos a seguir:

$$\begin{aligned} A(q) &= 1 - a_1 q^{-1} - \ldots - a_{n_y} q^{-n_y}, \\ B(q) &= b_1 q^{-1} - \ldots - b_{n_u} q^{-n_u}, \\ C(q) &= 1 + c_1 q^{-1} + \ldots + c_{n_v} q^{-n_v}, \\ D(q) &= 1 + d_1 q^{-1} + \ldots + d_{n_d} q^{-n_d}, \\ F(q) &= 1 + f_1 q^{-1} + \ldots + f_{n_f} q^{-n_f}. \end{aligned} \tag{4.2}$$

O modelo autoregressivo (AR, do inglês *autoregressive*) pode ser obtido tomando-se $C(q) = D(q) = F(q) = 1$ e, desconsiderado os sinais exógenos, ou seja, $u(k) = 0$. Nesse caso (4.1) pode ser reescrito como:

$$A(q)y(k) = v(k), \tag{4.3}$$

ou

$$y(k) = a_1 y(k-1) + a_2 y(k-2) + \ldots + a_{n_y} q^{-n_y} + v(k). \tag{4.4}$$

Os modelos AR são usados, frequentemente, para predição de séries temporais, ou situações em que somente se tem um sinal, $y(k)$. Nessas situações, deve-se estimar $A(q)$ usando o sinal $y(k)$, além de uma aproximação de $v(k)$ obtida através de uma distribuição de

probabilidade. Convencionou-se a indicação do modelo AR com polinômio $A(q)$ com ordem p, por AR(p), ou, considerando-se a equação (4.2), por AR(n_y).

4.1. Análise de Estacionariedade

De acordo com Hamilton (1994), um processo discreto é estacionário se para todo valor de k, a distribuição de probabilidade conjunta da série temporal $(y(k), y(k+1), y(k+2), ..., y(k+n))$ depende exclusivamente do intervalo de tempo separando as amostras $(k+1, k+2, k+3, ..., k+n)$ e não do momento em que as amostras ocorreram.

Considerando o modelo autorregressivo

$$y(k) = \rho y(k-1) + v(k) \tag{4.5}$$

a série temporal $y(k)$ converge ($k \to \infty$) para uma série estacionária, quando $|\rho| < 1$. Se $|\rho| \geq 1$ a série temporal não é estacionária. Sendo $|\rho| = 1$ a variância de $y(k)$ é $k\sigma^2$ e a série é conhecida como *random walk*. Caso $|\rho| > 1$, a variância da série temporal cresce exponencialmente a medida que k aumenta.

Em Dickey e Fuller (1979) foi definido o teste estatístico denominado *Dickey-Fuller test*, que verifica a hipótese nula da presença de um círculo unitário em um modelo autorregressivo. Utilizando o teste *Augmented Dickey-Fuller* (ADF) é possível verificar se um modelo autorregressivo é estacionário, ou se apresenta alguma tendência, sendo necessário, neste caso algum pré-processamento. A partir do teste ADF, executado através do MATLAB, é possível confirmar que o teste rejeita a hipótese de círculo unitário em um modelo autorregressivo das séries temporais em questão, indicando que o comportamento é estacionário.

4.2. Análise de Autocorrelação

A função de autocorrelação (ACF), como apresentado por Box *et al.* (2015), demonstra como a correlação entre duas amostras quaisquer de uma série temporal se alteram a medida que a separação entre elas se modifica. Conforme Nounou *et al.* (2000), um processo representado por ruído branco apresenta uma função de autocorrelação zero para todos os atrasos, excetuando o valor unitário para o atraso zero. Já um processo autocorrelacionado (**AR**, **ARMA** ou **ARIMA**), apresenta valores diferentes de zero para os atrasos, indicando uma correlação entre diferentes amostras. Comumente, para um sinal com erro $v(k)$, e sendo $Cov()$ a covariância de um sinal e $Var()$ a variância, a ACF é definida como:

$$\rho(n) = \frac{Cov(v(k), v(k+n))}{\sqrt{Var(v(k))Var(v(k+n))}}. \tag{4.6}$$

Para um sinal estocástico estacionário de variância σ^2, a equação (4.6) pode ser reduzida em

$$\rho(n) = \frac{Cov(v(k), v(k+n))}{\sigma^2}. \tag{4.7}$$

As análises de autocorrelação dos dados de teor de ferro e sílica (amostrados e interpolados), apresentados na Seção 3.2, demonstram comportamentos semelhantes, como apresentado nas Figuras 4.1, 4.2, 4.3 e 4.4, contendo um decaimento e um padrão sinusoidal que, conforme Montgomery *et al.* (2015), trata-se de um padrão típico de séries estacionárias.

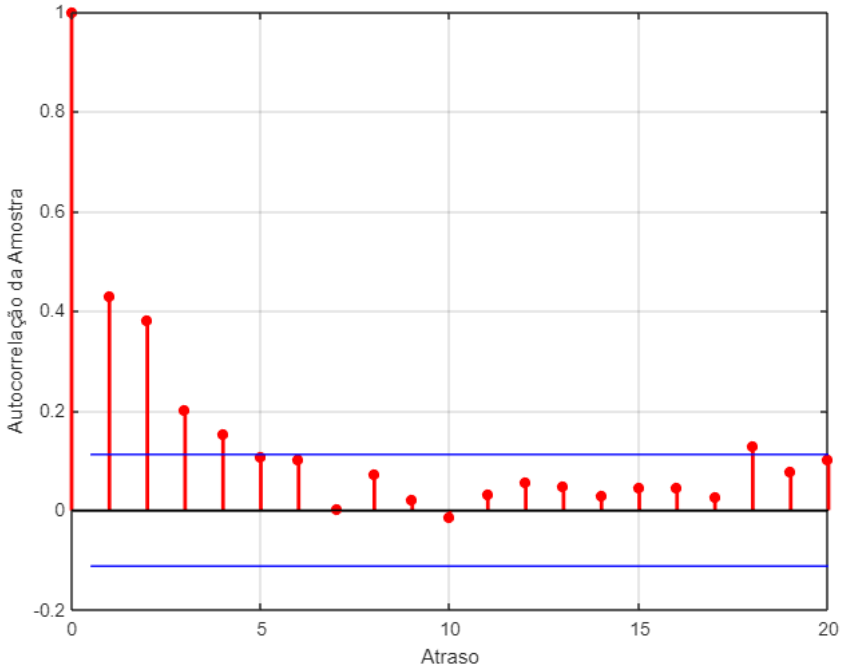

Figura 4.1: *ACF* da série temporal do teor de ferro (amostrado) na concentração magnética. Fonte: elaborada pelo autor

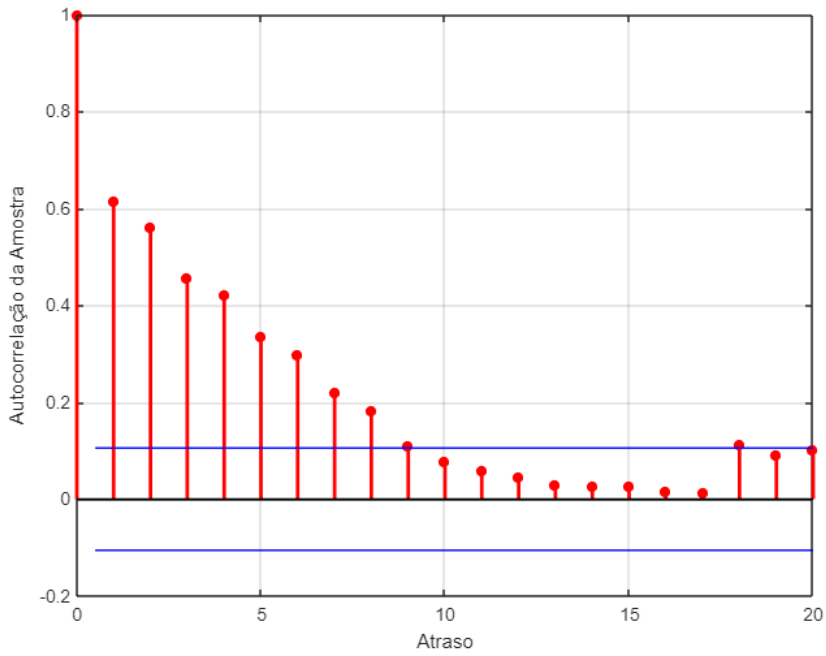

Figura 4.2: *ACF* da série temporal do teor de ferro (interpolado) na concentração magnética.
Fonte: elaborada pelo autor

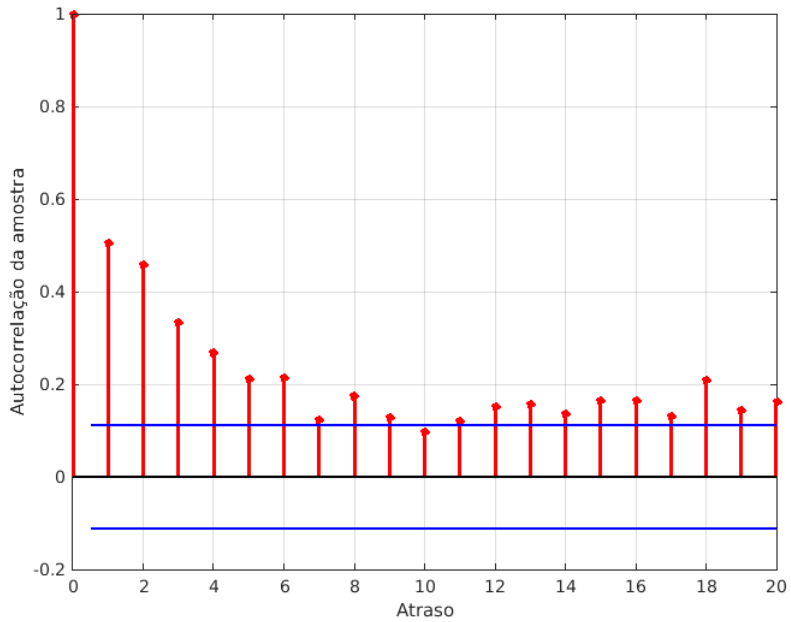

Figura 4.3: *ACF* da série temporal do teor de sílica (amostrado) na concentração magnética.
Fonte: elaborada pelo autor

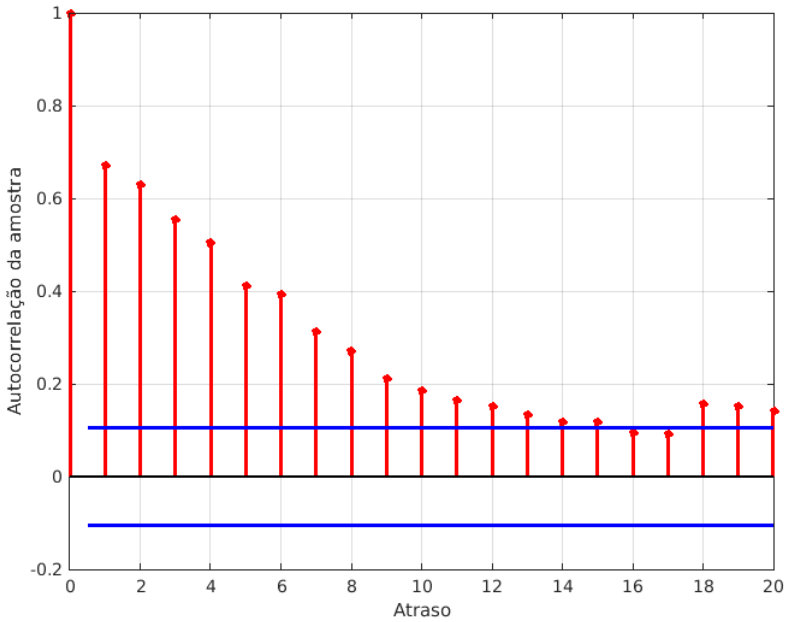

Figura 4.4: *ACF* da série temporal do teor de sílica (interpolado) na concentração magnética. Fonte: elaborada pelo autor

É possível identificar que as análises das bases de dados que foram obtidas de forma interpolada (Figuras 4.2 e 4.4) apresentam um decaimento mais contínuo, indicando maior autocorrelação entre as amostras. Este comportamente é justificado pelo fato de alguns dados serem obtidos pela interpolação linear de seus pares, aumentando a correlação da base de dados como um todo.

Comportamento semelhante ao apresentado pela ACF das séries temporais da concentração magnética, pode ser verificado também na análise ACF da série temporal do teor de ferro alimentado na flotação reversa da ITMI de Vargem Grande. O mesmo comportamento de decaimento com padrão sinusoidal é apresentado na Figura 4.5.

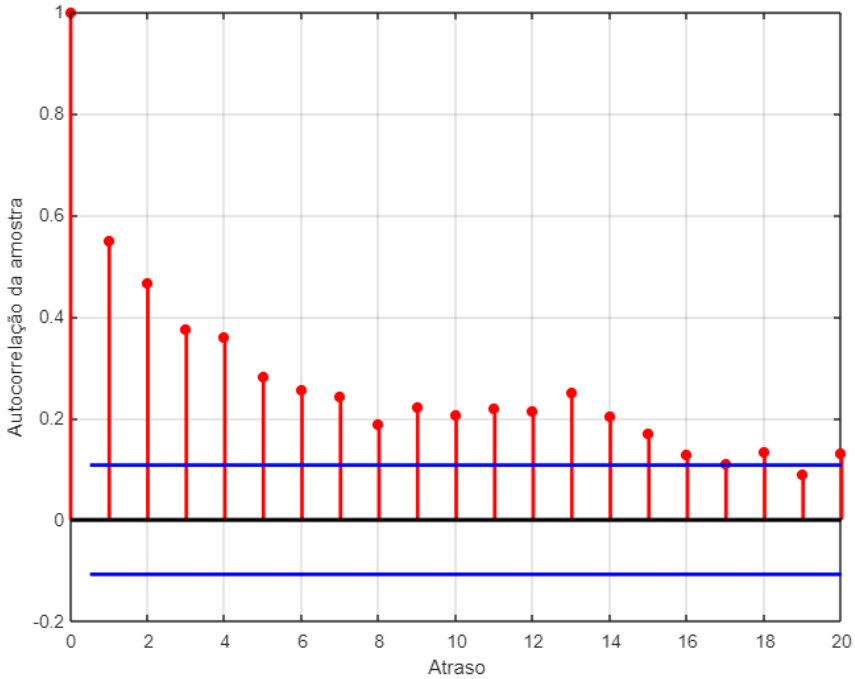

Figura 4.5: *ACF* da série temporal do teor de ferro (amostrado) na flotação reversa. Fonte: elaborada pelo autor

4.3. Análise de Autocorrelação Parcial

Como apresentado por Montgomery *et al.* (2015), a função de autocorrelação parcial (PACF) entre $y(k)$ e $y(k-n)$ equivale à função de autocorrelação entre $y(k)$ e $y(k-n)$ após realizados ajustes para $y(k-1)$, $y(k-2)$, ..., $y(k-n+1)$. Sendo $y(k)$ um modelo de série temporal estacionária (não necessariamente um modelo AR). A princípio, as Equações de Yule-Walker[1] da ACF de um modelo AR(p) são dadas por:

$$\rho(j) = \sum_{i=1}^{n} \phi_{in}\rho(j-i), j = 1,2,...,n \tag{4.8}$$

podendo ser reescrito na notação matricial, como representada

$$\begin{bmatrix} \rho(1) \\ \rho(2) \\ \rho(3) \\ \vdots \\ \rho(n) \end{bmatrix} = \begin{bmatrix} 1 & \rho(1) & \rho(2) & \cdots & \rho(n-1) \\ \rho(1) & 1 & \rho(3) & \cdots & \rho(n-2) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho(n-1) & \rho(n-2) & \rho(n-3) & \cdots & 1 \end{bmatrix} \begin{bmatrix} \phi_{1n} \\ \phi_{2n} \\ \phi_{3n} \\ \vdots \\ \phi_{nn} \end{bmatrix} \tag{4.9}$$

[1]Conhecido método estatístico que fornece uma correlação direta entre os parâmetros de um modelo AR e sua função de covariância.

Para quaisquer valores de n, o último coeficiente ϕ_{nn} é chamado de correlação parcial do processo para o atraso n. Nesse caso, para um processo AR(p), $\phi_{nn} = 0$ para $n > p$. Sendo assim, diz-se que a função PACF interrompe após atraso p para um processo AR(p).

As análises de autocorrelação parcial dos dados de teor de ferro e sílica (amostrados e interpolados), como apresentado nas Figuras 4.6, 4.7, 4.8 e 4.9 apresentam comportamentos semelhantes, um decaimento abruto após o atraso 2, se aproximando de zero, considerando os limites de significância estatística.

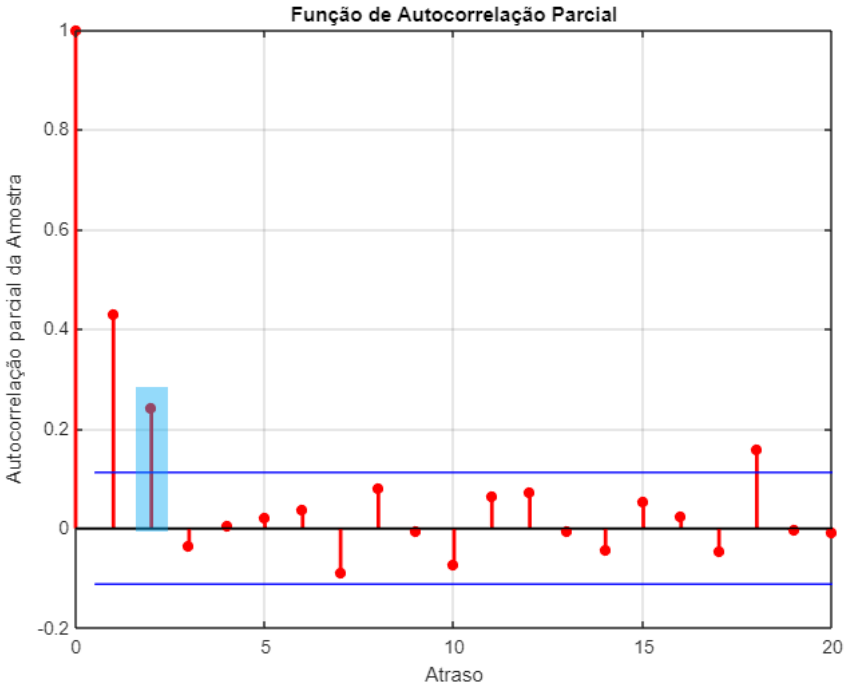

Figura 4.6: *PACF* da série temporal do teor de ferro (amostrado) na concentração magnética. Fonte: elaborada pelo autor

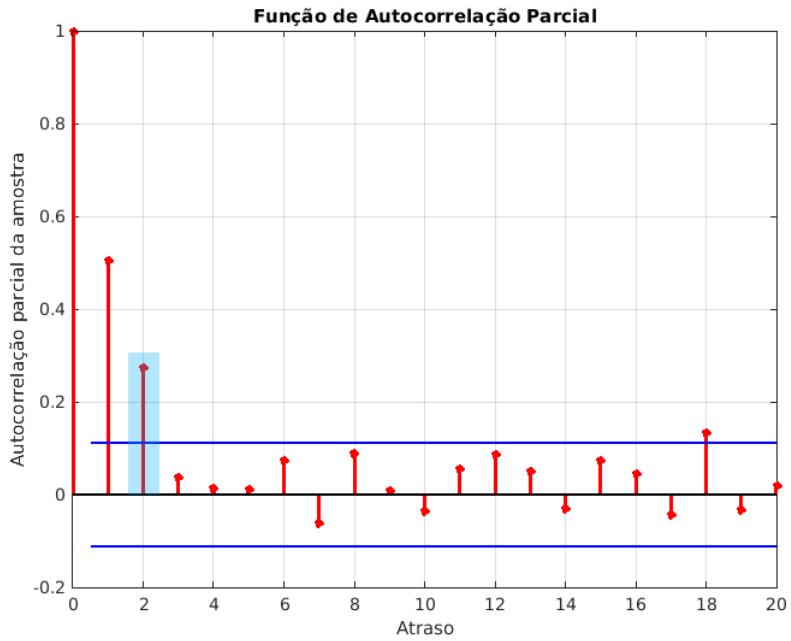

Figura 4.7: *PACF* da série temporal do teor de ferro (interpolado) na concentração magnética.
Fonte: elaborada pelo autor

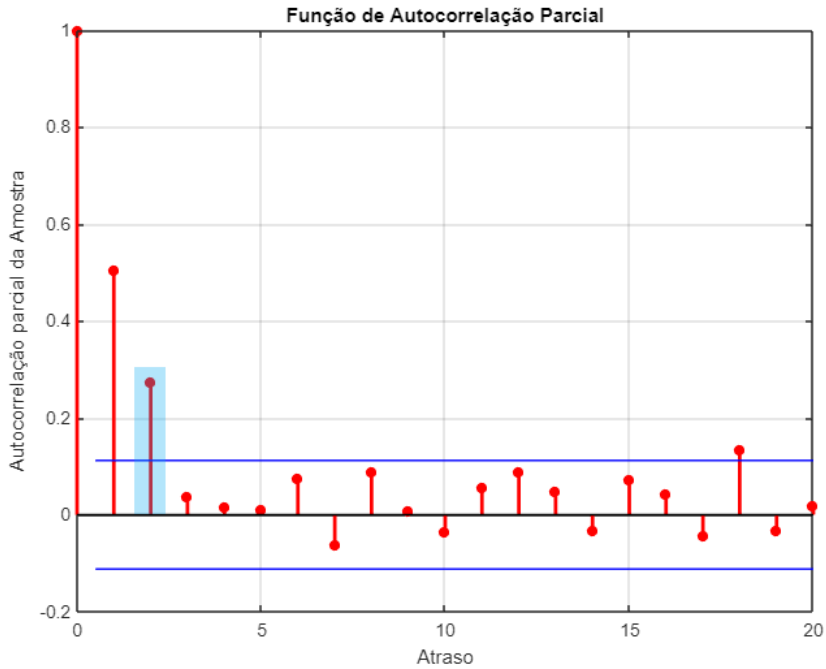

Figura 4.8: *PACF* da série temporal do teor de sílica (amostrado) na concentração magnética.
Fonte: elaborada pelo autor

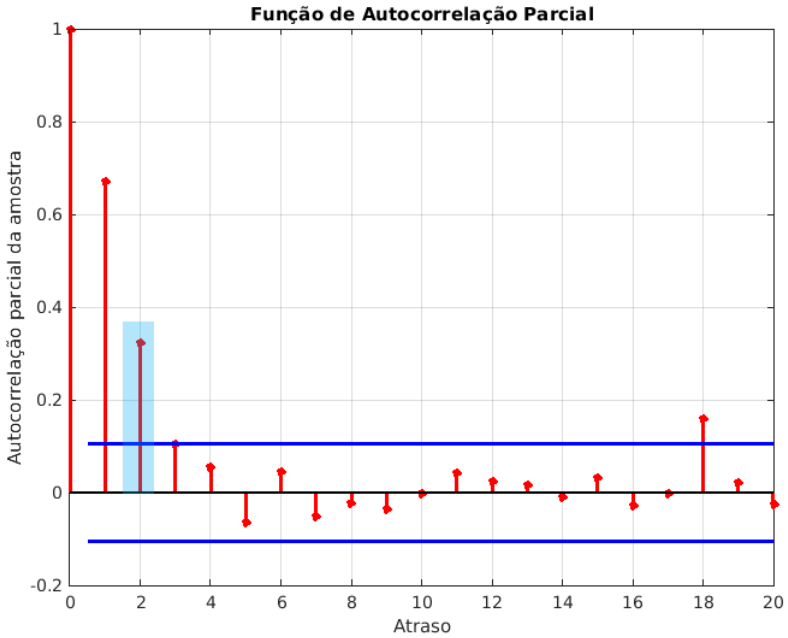

Figura 4.9: *PACF* da série temporal do teor de sílica (interpolado) na concentração magnética. Fonte: elaborada pelo autor

A Tabela 4.1, como descrita por Montgomery *et al.* (2015), apresenta o comportamento de autocorrelação e autocorrelação parcial teóricos para modelos estacionários. Uma das possibilidades de comportamento é de um decaimento aproximadamente exponencial ou sinusoidal, com um número relativamente considerável de valores diferentes de zero. Por outro lado, outra possibilidade seria de um comportamento com decaimento abruto, com apenas alguns valores com significância estatística diferentes de zero.

Através do comportamento teórico apresentado pela Tabela 4.1, e considerando os comportamentos apresentados pelas análises de ACF (Figuras 4.1 a 4.4) e de PACF (Figuras 4.6 a 4.9), podemos considerar que o modelo autorregressivo de segunda ordem - **AR(2)** - é um bom candidato para representar o comportamento da séries temporais dos teores de ferro e sílica, sejam das bases de dados obtidas apenas dos pontos amostrados, ou interpolados.

Tabela 4.1: Comportamentos teóricos para modelos estacionários.

Modelo	**ACF**	**PACF**
AR(p)	Decaimento exponencial	Decaimento abrupto após p
MA(q)	Decaimento abrupto após q	Decaimento exponencial
ARMA(p,q)	Decaimento exponencial	Decaimento exponencial

Assim, como verificado para as análises de PACF das séries temporais da concentração magnética da Mina de Fábrica, é possível averiguar que a análise PACF do teor de ferro da

flotação reversa da ITMI de Vargem Grande também apresenta um decaimento abrupto após o atraso 2. Conforme demonstrado pela Figura 4.10 e, considerando os comportamentos teóricos apresentados na Tabela 4.1, é possível concluir que o modelo autorregressivo de segunda ordem - **AR(2)** - também é um bom candidato para representar o comportamento do teor de ferro da flotação reversa da ITMI de Vargem Grande.

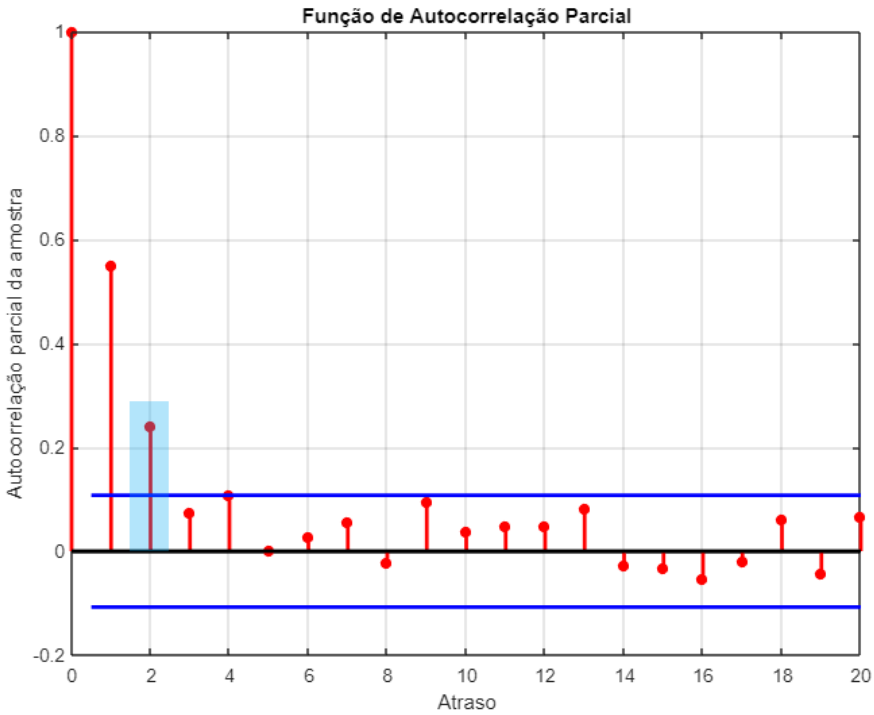

Figura 4.10: *PACF* da série temporal do teor de ferro (amostrado) na flotação reversa. Fonte: elaborada pelo autor

4.4. Identificação dos Modelos

Como apresentado por da Silva (2014), o procedimento para a identificação dos modelos pode ser constituído pelos seguintes passos:

- Projeto do experimento;
- Coleta de dados;
- Escolha da estrutura do modelo;
- Escolha do método para estimação do modelo;
- Validação do modelo.

Os passos descritos acima podem ser representados pelo fluxograma de identificação de sistemas, retratado na Figura 4.11.

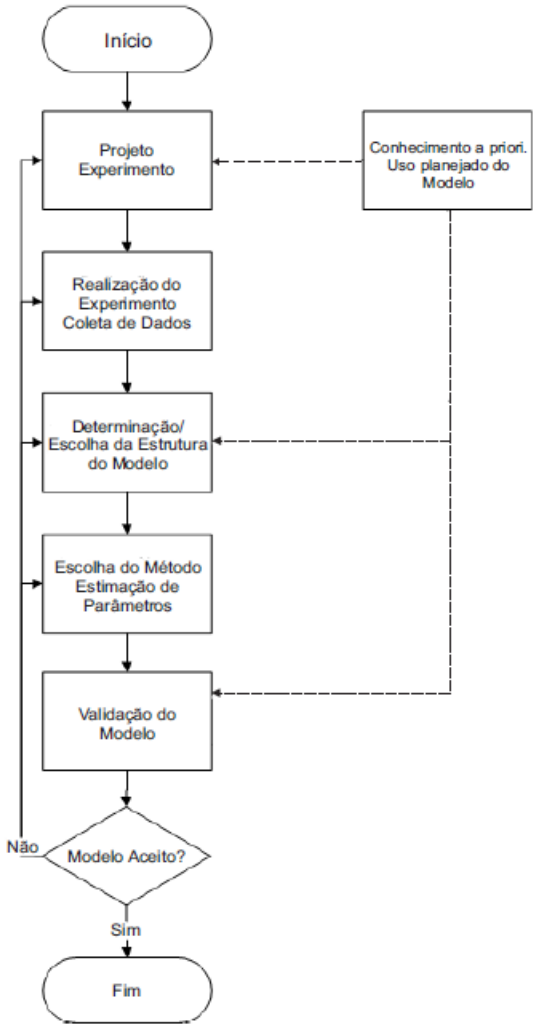

Figura 4.11: Fluxograma para identificação de sistemas. Fonte: Söderström e Stoica (1989)

Após determinar a estrutura e a ordem do modelo, é necessário estimar os respectivos parâmetros. O método usado nesta etapa é o método dos mínimos quadrados recursivo. Este método é escolhido devido a característica dinâmica dos dados do processo.

O principal objetivo é obter um modelo que forneça uma predição dos teores de ferro e sílica dos minerais alimentados nas plantas de beneficiamento mineral. Assim, é obtida uma representação mais próxima da realidade do que a utilizada comumente, a do modelo ingênuo (*naive model*). O modelo ingênuo define o último valor observado como uma previsão para o valor futuro que deseja-se estimar, ou seja:

$$y(k+1) = y(k). \tag{4.10}$$

4.4.1. O Algoritmo dos Mínimos Quadrados

Como apresentado por Isermann e Münchhof (2010), considere a tarefa fundamental de identificação de um modelo autorregressivo, como sendo a estimação dos parâmetros deste modelo, que pode ser formulada de acordo com:

$$\theta^T = (\theta_1 \, \theta_2 \, ... \, \theta_m) \tag{4.11}$$

Assumindo-se que o processo em questão segue leis físicas descritas pelo conjunto de parâmetros θ e, neste caso, para um sistema em que só é possível realizar medição da saída $y_u(k)$, a mesma seria representada por:

$$y_u(k) = f(\theta). \tag{4.12}$$

No entanto, normalmente é impossível medir diretamente a saída do processo, sendo possível medir apenas tal variável adicionada de distúrbios e ruídos de medição $n(k)$. Neste caso, conforme representado pela Figura 4.12, o modelo do processo é que passa a ser representado por:

$$y_M = f(\theta). \tag{4.13}$$

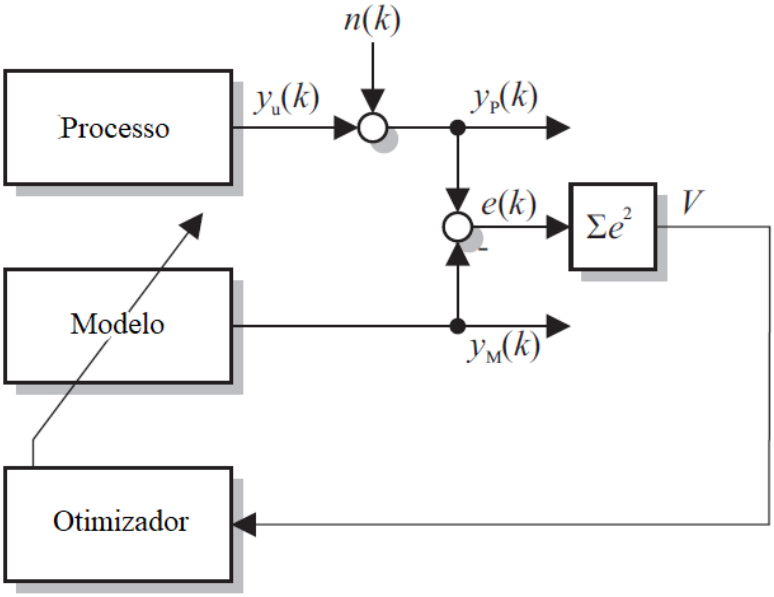

Figura 4.12: Diagrama do arranjo geral do médodo dos Mínimos Quadrados. Fonte: Isermann e Münchhof (2010)

O erro de observação é definido como a diferença entre a saída possível de ser medida (considerando os distúrbios e ruídos) $y_P(k)$, e a saída do modelo $y_M(k)$:

$$e(k) = y_P(k) - y_M(k) \tag{4.14}$$

O método dos Mínimos Quadrados consiste em determinar o mínimo da soma dos erros quadrados, ou seja:

$$V = e^2(1) + e^2(2) + \ldots + e^2(N) = \sum_{k=1}^{N} (e(k))^2 \tag{4.15}$$

4.4.2. O Algoritmo dos Mínimos Quadrados Recursivos

No método dos mínimos quadrados, conforme demonstrado por Aguirre (2004), dado um sistema matricial

$$y = \Psi\hat{\theta} + \xi, \tag{4.16}$$

sendo $\xi \in \mathbb{R}^N$ o vetor de resíduos. É possível observar que $\xi = y - \Psi\hat{\theta}$, ou seja, os resíduos são formados pela diferença entre o vetor de variáveis independentes y (no caso em questão os valores amostrados dos teores) e do vetor de valores dos regressores Ψ, através do vetor

de parâmetros estimados $\hat{\theta}$. Busca-se o melhor modelo aproximado, neste caso, um vetor de parâmetros $\hat{\theta}$ que minimize ξ. Sendo a função de custo dos mínimos quadrados dada por:

$$\sum_{k=1}^{N} \xi(k)^2 = \xi^T \xi = \|\xi\|^2. \tag{4.17}$$

Resolvendo o gradiente desta função de custo, obtém-se a equação dos parâmetros do sistema matricial (4.16), através da seguinte equação:

$$\hat{\theta}(k) = (\Psi^T(k)\Psi(k))^{-1}\Psi^T(k)y(k). \tag{4.18}$$

De acordo com Isermann e Münchhof (2010), para o algoritmo dos mínimos quadrados recursivos, tem-se:

$$P(k) = (\Psi^T(k)\Psi(k))^{-1}, \tag{4.19}$$

$$y(k) = \begin{pmatrix} y(1) \\ y(2) \\ \vdots \\ y(k) \end{pmatrix}, \tag{4.20}$$

$$\Psi(k) = \begin{pmatrix} \psi^T(1) \\ \psi^T(2) \\ \vdots \\ \psi^T(k) \end{pmatrix}, \tag{4.21}$$

e sendo

$$\psi^T = [-y(k-1),...,-y(k-m)|u(k-d-1),...,u(k-d-m)]. \tag{4.22}$$

A estimação dos parâmetros para o passo $k+1$ pode ser dada por:

$$\hat{\theta}(k+1) = P(k+1)\Psi^T(k+1)y(k+1), \tag{4.23}$$

que pode ser separada da seguinte forma:

$$\begin{aligned}\hat{\theta}(k+1) &= P(k+1)\begin{pmatrix}\Psi(k)\\ \psi^T(k+1)\end{pmatrix}\begin{pmatrix}y(k)\\ y(k+1)\end{pmatrix}\\ &= P(k+1)(\Psi(k)y(k)+\psi^T(k+1)y(k+1))\end{aligned} \tag{4.24}$$

Baseado na Equação (4.18), a substituição $\Psi(k)y(k) = P^{-1}(k)\hat{\theta}(k)$, obtendo:

$$\hat{\theta}(k+1) = \hat{\theta}(k) + (P(k+1)P^{-1}(k) - I)\hat{\theta}(k) + P(k+1)\psi(k+1)y(k+1). \tag{4.25}$$

De acordo com (4.19),

$$\begin{aligned}P(k+1) &= \left(\begin{pmatrix}\Psi(k)\\ \psi^T(k+1)\end{pmatrix}^T\begin{pmatrix}\Psi(k)\\ \psi^T(k+1)\end{pmatrix}\right)^{-1}\\ &= (P^{-1}(k)+\psi(k+1)\psi^T(k+1))^{-1},\end{aligned} \tag{4.26}$$

portanto:

$$P^{-1}(k) = P^{-1}(k+1) - \psi(k+1)\psi^T(k+1). \tag{4.27}$$

Em conjunto com (4.25), pode-se obter

$$\hat{\theta}(k+1) = \hat{\theta}(k) + P(k+1)\psi(k+1)(y(k+1)\psi^T(k+1)\hat{\theta}(k)) \tag{4.28}$$

onde:

$\hat{\theta}(k+1)$ = Novo conjunto de parâmetros estimados;
$\hat{\theta}(k)$ = Antigo conjunto de parâmetros estimados;
$P(k+1)\psi(k+1)$ = Vetor de correção;
$y(k+1)$ = Nova medição;
$\psi^T(k+1)\hat{\theta}(k)$ = Valor predito baseado no conjunto anterior de parâmetros estimados.

Neste sentido, a formulação recursiva do problema de estimação é encontrada. Considerando o erro da equação dado por:

$$(y(k+1)\psi^T(k+1)\hat{\theta}(k)) = e(k+1). \tag{4.29}$$

Finalmente, a equação (4.28) pode ser reescrita como:

$$\hat{\theta}(k+1) = \hat{\theta} + P(k+1)\psi(k+1)e(k+1), \tag{4.30}$$

As equações (4.30), (4.22) e (4.21), quando reescritas na forma da equação (4.16), permitem realizar a predição de um passo a frente do modelo com os parâmetros e amostras realizadas até o passo k.

Como o modelo escolhido para ser utilizado na predição, tanto do ferro quanto da sílica, é o autorregressivo de segunda ordem - AR(2) - o vetor de parâmetros $\hat{\theta}$ é formado por dois parâmetros distintos, $\hat{\theta}_1$ e $\hat{\theta}_2$.

De acordo com Isermann e Münchhof (2010) é necessário definir um peso maior das medidas recentes em relação as medições antigas, caso o algoritmo recursivo seja utilizado na estimação de parâmetros de processos que sejam levemente variantes no tempo. Assim, deve-se considerar um fator de esquecimento, que pode ser incorporado ao algoritmo original, dado por:

$$w(k) = \lambda^{N-k}, 0 < \lambda < 1, \tag{4.31}$$

Neste caso, os erros $e(k)$ são contabilizados com os pesos $w(k)$, considerando fator de esquecimento λ exponencial. A escolha deste fator deve ser realizada considerando um compromisso entre melhor supressão de distúrbios ($\lambda \to 1$) e melhor predição de sistemas variantes no tempo ($\lambda < 1$).

O código desenvolvido no ambiente MATLAB, baseado no desenvolvimento teórico apresentado, pode ser encontrado no Apêndice B. O código foi desenvolvido de forma que sejam lidos os valores históricos, previamente registrados, do teor que pretende-se realizar a predição. Além disso, é possível variar tanto o parâmetro do fator de esquecimento λ, quanto a ordem do modelo[2]. Inicialmente, é utilizado o algoritmo dos mínimos quadrados, com os primeiros $N0$ valores, de forma a obter os valores iniciais dos parâmetros do modelo autorregressivo. Uma vez obtidos os valores iniciais dos parâmetros, a execução do código passa a ser baseada no algoritmo dos mínimos quadrados recursivos, que utiliza os valores anteriores dos parâmetros do modelo, o histórico da série temporal e o último valor medido para realizar a predição de um passo a frente.

[2]Para todos os cenários testados, considerando teor de ferro e sílica, para os processos de concentração magnética da Mina de Fábrica e flotação reversa da ITMI de Vargem, a ordem obtida foi 2, ou seja, sugere-se a utilização do modelo AR(2), porém, caso a análise para outros processos demonstre que a ordem ideal é maior do que 2, este parâmetro pode ser alterado.

4.5. Avaliação de Desempenho do Modelo

De acordo com Montgomery *et al.* (2015), a avaliação do desempenho dos modelos de predição deve ser realizada verificando a capacidade da técnica de predição de efetivamente predizer as amostras futuras. Diversas análises estatísticas podem ser utilizadas para descriminar o melhor entre os modelos em avaliação. Neste trabalho, utilizaremos as seguintes análises estatísticas:

4.5.1. RMSE - *Root Mean Square Error*

O índice *Root Mean Square Error* (RMSE), pode ser interpretado como a raiz quadrada das médias dos erros entre os valores medidos e os valores preditos pelo modelo. A representação deste índice pode ser definida como:

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n} e_i^2} \tag{4.32}$$

A consideração central quando da utilização deste índice, conforme Chai e Draxler (2014), é que os erros das amostras não sejam tendenciosos, mantendo uma distribuição relativamente normal.

4.5.2. MAPE - *Mean Absolute Percent Error*

Para utilizar esta análise estatística, considerando o erro de predição dos modelos, define-se o erro relativo de predição (em percentual) de um passo a frente, como sendo:

$$re_k(1) = \frac{y_k - \hat{y}_k(k-1)}{y_k} \times 100 = \frac{e_k(1)}{y_k} \times 100, \tag{4.33}$$

assim , o valor MAPE de um modelo de predição de série temporal pode ser definido por:

$$MAPE = \frac{1}{n}\sum_{k=1}^{n} |re_k(1)|. \tag{4.34}$$

4.5.3. Coeficiente U de Theil

Esta análise estatística avalia quanto os resultados obtidos por um modelo de predição são melhores do que uma previsão ingênua (*naive*) ou trivial, ou seja, quando a melhor estimativa do próximo valor é o próprio valor atual. O coeficiente U de Theil é dado por:

$$U = \sqrt{\frac{\sum_{k=1}^{n}(y(k) - \hat{y}(k))^2}{\sum_{k=1}^{n}(y(k) - y(k-1))^2}}. \tag{4.35}$$

Através deste coeficiente é possível analisar a qualidade de uma previsão através dos seguintes valores do coeficiente:

- Quando $U > 1$, o erro do modelo é maior do que o erro na previsão ingênua;
- Quando $U < 1$, o erro do modelo é menor que o erro na previsão ingênua.

4.6. Resultados da Predição do Modelo AR

Nesta seção serão apresentados os resultados de predição do modelo AR para cada um dos diferentes cenário avaliados, a saber:

- Teor de ferro amostrado da alimentação da concentração magnética da Mina de Fábrica;
- Teor de ferro com interpolação de dados da alimentação da concentração magnética da Mina de Fábrica;
- Teor de sílica amostrado da alimentação da concentração magnética da Mina de Fábrica;
- Teor de sílica com interpolação de dados da alimentação da concentração magnética da Mina de Fábrica;

Em função dos resultados apresentados, será avaliado se a melhor condição de predição dos teores de ferro e sílica ocorre para os dados amostrados ou para a base de dados com a interpolação dos pontos faltantes. Por fim, após esta avaliação, serão apresentados os resultados obtidos para a alimentação da flotação da ITMI de Vargem Grande. Dessa forma, pretende-se demonstrar que o desenvolvimento realizado para estes dois cenários distintos pode ser estendido para diversos outros processos que apresentem características semelhantes.

Do ponto de vista do controle de processo, a predição de um passo a frente já é suficiente para a tomada de decisão e ajustes nos parâmetros e variáveis de controle (corrente de campo, velocidade de giro, pressões de água de médio/concentrado para a concentração magnética; dosagem de reagentes, nível da camada de espuma, vazões de alimentação e saída para a flotação reversa). Portanto, os resultados apresentados abaixo, foram obtidos considerando esta condição.

Para situações em que os teores de ferro e sílica no concentrado estão fora dos limites estipulados, os engenheiros de processo e de automação necessitam fazer ajustes nos processos. Nestas situações, mesmo que não seja possível realizar a predição exata dos teores da polpa de minério que está sendo alimentada, conhecer a tendência de alta ou queda dos mesmos já indica para os engenheiros qual deve ser o sentido dos ajustes nos parâmetros. O objetivo desta informação é demonstrar se a predição está indicando a tendência ascendente ou descendente adequadamente. Ou seja, se o valor predito atual demonstrou crescimento em relação ao valor medido anterior, e se o valor medido atual também demonstrou crescimento em relação

ao anterior, é considerado acerto da tendência. O mesmo ocorre para o caso em que ambos apresentam redução. A definição deste índice pode ser descrita pela Equação (4.36).

$$\text{Tendência} = \begin{cases} \text{Crescente}, & y_M(k+1) - y_P(k) > 0, \\ \text{Decrescente}, & \text{caso contrario.} \end{cases} \tag{4.36}$$

Para avaliar o percentual de acerto da tendência da predição do teor, realiza-se o seguinte cálculo:

$$(y_M(k+1) - y_P(k)) * (y_P(k+1) - y_P(k)) > 0 \tag{4.37}$$

onde, $y_P(k)$ é a saída possível de ser medida, e $y_M(k)$ é a saída do modelo, ou a predição.

4.6.1. Teor de Ferro na alimentação da concentração magnética da Mina de Fábrica

A partir dos dados históricos (Figura 3.3) e utilizando o algoritmo dos mínimos quadrados recursivos apresentado na Seção 4.4, foi realizada a predição de um passo a frente do teor de ferro. Esta predição permite, conforme apresentado anteriormente, que os engenheiros de automação e de processos da planta de beneficiamento mineral possam realizar os devidos ajustes no processo no instante adequado.

Conforme apresentado por Aguirre (2004), recomenda-se que o fator de esquecimento do algoritmo dos Mínimos Quadrados Recursivo seja escolhido dentro da faixa $0{,}95 \geq \lambda \geq 1{,}00$. Apenas a título de verificação desta boa prática, foi realizada também a simulação da predição para o valor 0,5 do parâmetro.

Resultados para o teor de ferro amostrado

A Tabela 4.2 apresenta os resultados dos três índices de desempenho (Seção 4.5) para diferentes valores do parâmetro do fator de esquecimento λ. Foi incluído também o índice de acerto da tendência da predição.

Tabela 4.2: Resultados de predição do teor de ferro amostrado da alimentação da concentração magnética

λ	RMSE	MAPE	U de Theil	%Tendência
Naive	3,6351	5,3093		
1,00	**3,2782**	**4,6807**	**0,7849**	**98,12%**
0,99	3,2949	4,7019	0,7875	98,12%
0,98	3,3155	4,7299	0,7899	97,81%
0,97	3,3382	4,7719	0,7927	97,19%
0,96	3,3629	4,813	0,7958	96,88%
0,95	3,3897	4,8571	0,7992	96,56%
0,5	6,7618	8,3984	1,3922	74,69%

Como pode ser verificado, de acordo com a Tabela 4.2, o melhor resultado obtido, em todos os três índices, foi com o fator de esquecimento $\lambda = 1$. Este resultado demonstra que, para obtenção do melhor desempenho de predição, todas as amostras da série temporal devem ter o mesmo peso no cálculo dos mínimos quadrados. A variação dos índices de desempenho indica, apesar de a variação ser relativamente pequena, quanto menor o valor do fator de esquecimento, menor é a eficiência da predição.

Foi possível verificar também, conforme apresentado por Aguirre (2004) e por Isermann e Münchhof (2010), que a faixa de variação ideal para o fator de esquecimento é de $0{,}95 \leq \lambda \leq 1{,}00$, e que o fator com valores muito inferiores a este patamar acarretam na perda significativa da memória da série temporal, degradando seu desempenho. Os resultados obtidos para $\lambda = 0{,}5$ demonstram que o desempenho da predição ficou pior, inclusive, que o desempenho da predição *Naive*, para os três índices de desempenho analisados.

Um ponto relevante destes resultados é o fato de que, apesar do desempenho da predição do modelo AR(2) não ter demonstrado uma melhora tão significativa, se comparada à predição *Naive*, o percentual de acerto da tendência do teor de ferro é considerável, alcançando, para o melhor caso ($\lambda = 1$), 98,12% de acerto da tendência do comportamento do teor do minério de ferro.

As Figuras 4.13, 4.14 e 4.15 apresentam, respectivamente, o resultado da predição, a variação do erro de predição (comparado com o erro de predição do modelo *naive*) e a variação dos dois parâmetros do modelo AR(2).

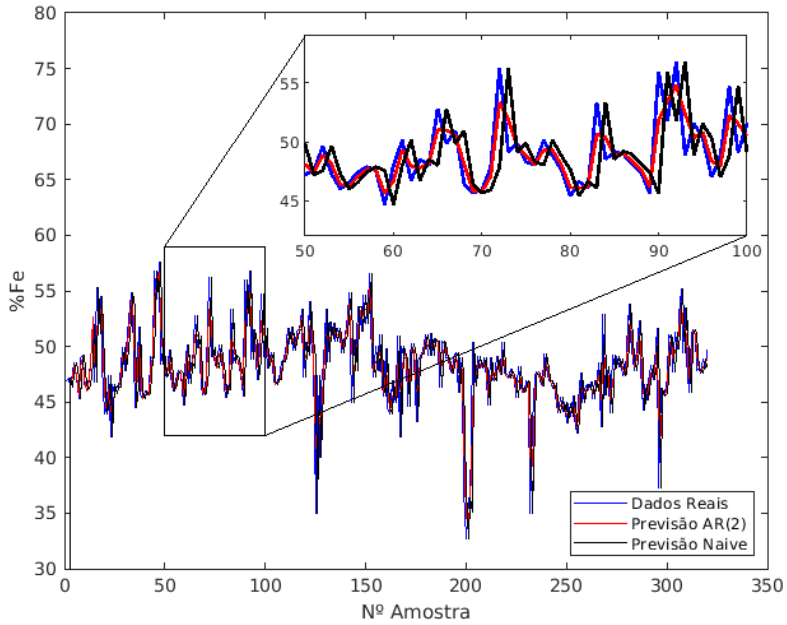

Figura 4.13: Resultado da predição do teor de ferro amostrado na alimentação da concentração magnética - $\lambda = 1$. Fonte: elaborada pelo autor.

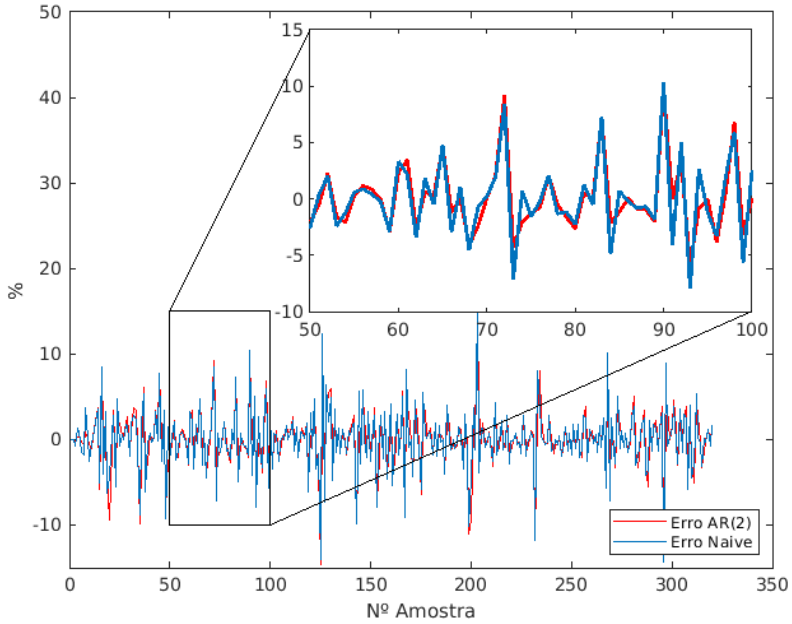

Figura 4.14: Erros da predição do teor de ferro amostrado na alimentação da concentração magnética - $\lambda = 1$. Fonte: elaborada pelo autor.

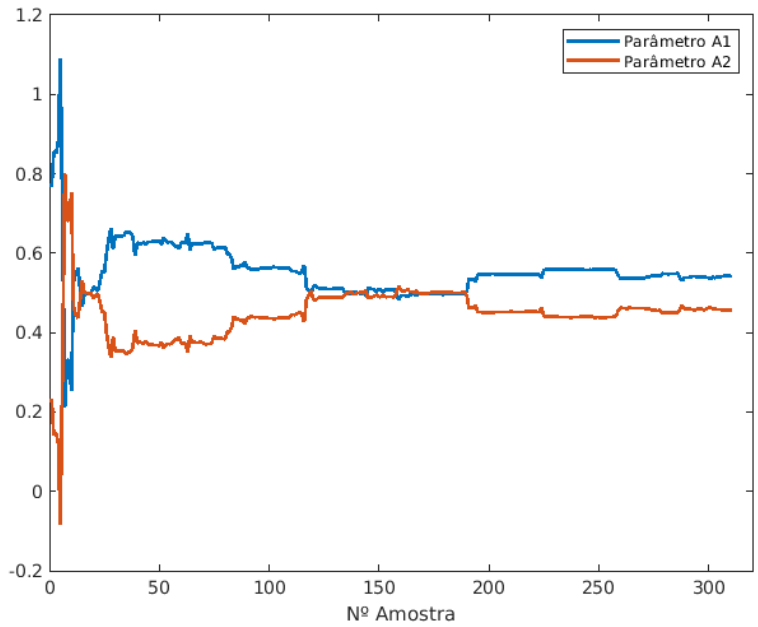

Figura 4.15: Parâmetros da predição do teor de ferro amostrado na alimentação da concentração magnética - $\lambda = 1$. Fonte: elaborada pelo autor.

Como foi possível verificar, o desempenho da predição do modelo AR(2) diminui a medida que o fator de esquecimento é reduzido. Como a variação entre os resultados obtidos, para a alteração do fator de esquecimento na faixa apresentada, é relativamente pequena, os gráficos para os demais valores de λ não serão apresentados. No entanto, como verificado que valores muito distantes desta faixa de variação degradam o desempenho da predição, é importante verificar os resultados obtidos para o valor do fator de esquecimento $\lambda = 0{,}5$. As Figuras 4.16, 4.17 e 4.18 apresentam, respectivamente, o resultado da predição, a variação do erro de predição (comparado com o erro de predição do modelo *naive* e a variação dos dois parâmetros do modelo AR(2).

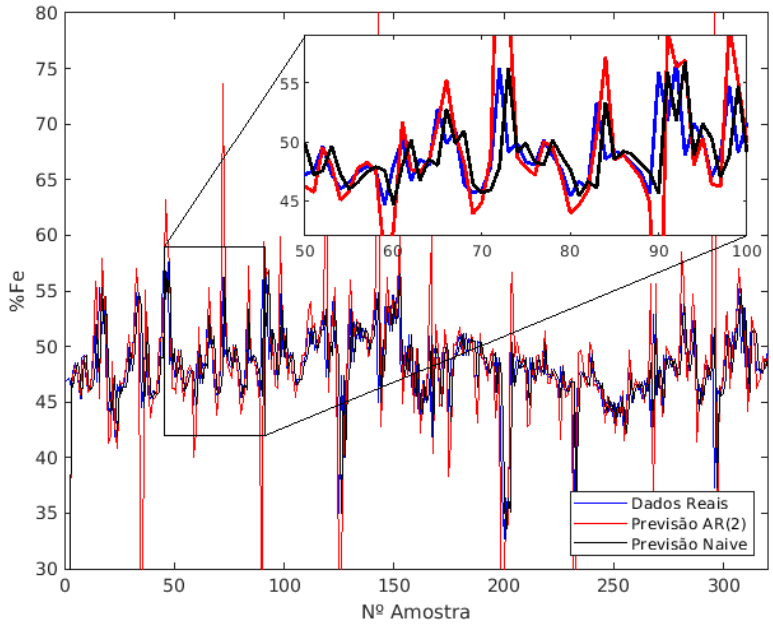

Figura 4.16: Resultado da predição do teor de ferro amostrado na alimentação da concentração magnética - $\lambda = 0{,}5$. Fonte: elaborada pelo autor.

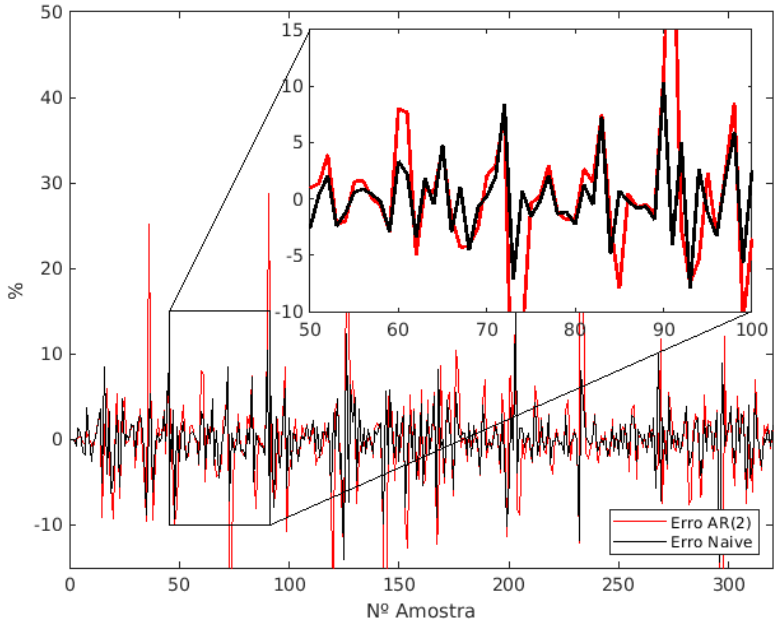

Figura 4.17: Erros da predição do teor de ferro amostrado na alimentação da concentração magnética - $\lambda = 0{,}5$. Fonte: elaborada pelo autor.

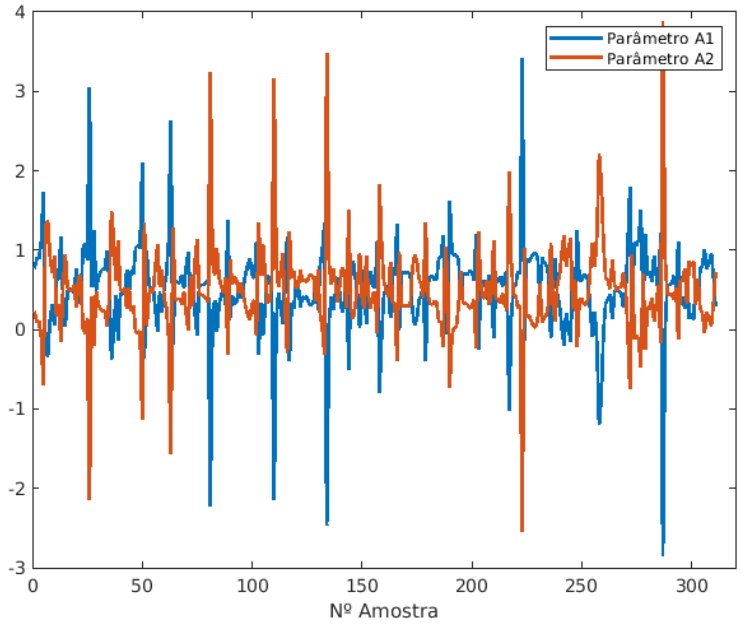

Figura 4.18: Parâmetros da predição do teor de ferro amostrado na alimentação da concentração magnética - $\lambda = 0{,}5$. Fonte: elaborada pelo autor.

Resultados para o teor de ferro considerando amostras interpoladas

A partir dos dados históricos considerando dados interpolados (Figura 3.4) e utilizando o algoritmo dos mínimos quadrados recursivos apresentado na Seção 4.4, foi realizada a predição de um passo a frente do teor de ferro.

Assim como apresentado para a base de dados contendo apenas os dados amostrados, a Tabela 4.3 apresenta os resultados dos três índices de desempenho (Seção 4.5) para diferentes valores do parâmetro do fator de esquecimento λ. Foi incluído também o índice de acerto da tendência da predição.

Tabela 4.3: Resultados de predição do teor de ferro interpolado da alimentação da concentração magnética

λ	RMSE	MAPE	U de Theil	%Tendência
Naive	3,2291	4,7205		
1,00	**2,9496**	**4,3231**	**0,7964**	**98,61%**
0,99	2,9631	4,3422	0,7972	98,89%
0,98	2,9832	4,3713	0,7979	98,61%
0,97	3,0063	4,4099	0,7995	98,06%
0,96	3,0309	4,4518	0,8016	97,50%
0,95	3,0563	4,4898	0,804	97,22%
0,5	6,4012	7,6049	1,4189	76,94%

Os resultados obtidos para o cenário considerando a base com dados interpolados foram muito semelhantes àqueles obtidos considerando apenas os dados amostrados, ou seja, o desempenho da predição do modelo AR(2), neste caso, é inversamente proporcional ao valor do fator de esquecimento.

Importante destacar que, apesar de o comportamento ser semelhante, considerando os resultados apresentados pelo índice *U de Theil*, os desempenhos de predição foram cerca de 1,5% melhores no cenário considerando apenas os dados amostrados. O fato deste índice realizar uma comparação com o desempenho da predição *naive* é interessante, pois a interpolação dos dados afeta também o desempenho deste método, tornando este índice mais apropriado para a comparação e, consequentemente, escolha do melhor cenário.

Ao se comparar o desempenho dos índices RMSE e MAPE, obtidos no cenário dos dados amostrados, com aqueles obtidos para os dados interpolados, é possível verificar que os índices foram menores no segundo cenário. Como ambos os índices realizam média de erros, e considerando que para os pontos interpolados os erros são inferiores aos pontos amostrados, o resultado final dos dois índices é inferior neste cenário.

As Figuras 4.19, 4.20 e 4.21 apresentam, respectivamente, o resultado da predição, a variação do erro de predição (comparado com o erro de predição do modelo *naive*) e a variação dos dois parâmetros do modelo AR(2) para os dados interpolados.

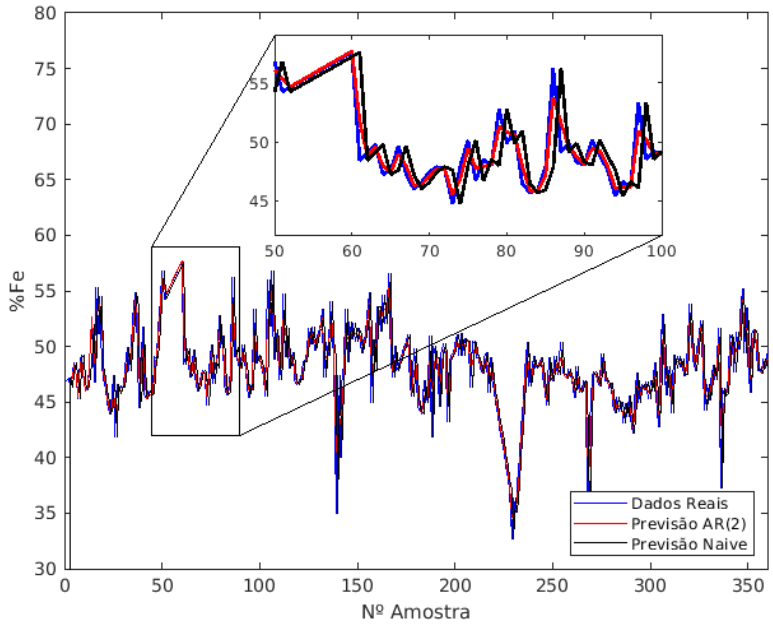

Figura 4.19: Resultado da predição do teor de ferro interpolado na alimentação da concentração magnética - $\lambda = 1$. Fonte: elaborada pelo autor.

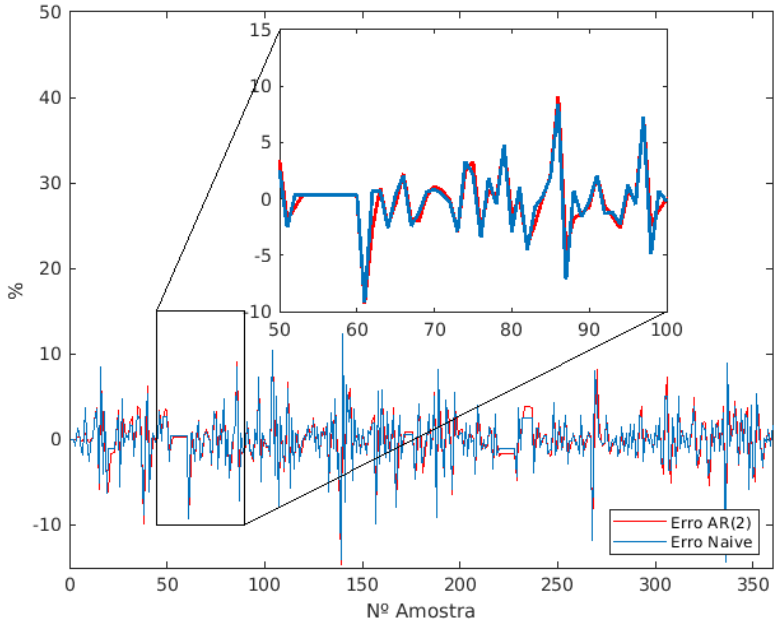

Figura 4.20: Erros da predição do teor de ferro interpolado na alimentação da concentração magnética - $\lambda = 1$. Fonte: elaborada pelo autor.

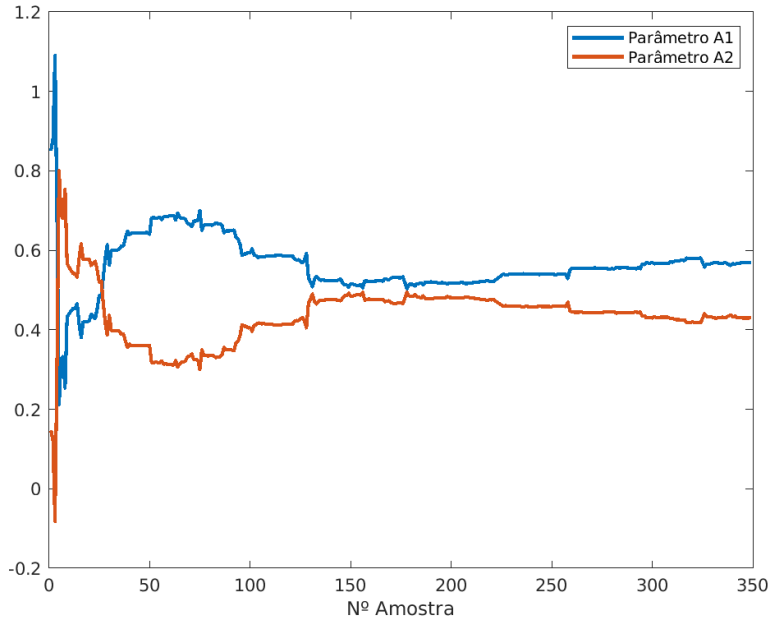

Figura 4.21: Parâmetros da predição do teor de ferro interpolado na alimentação da concentração magnética - $\lambda = 1$. Fonte: elaborada pelo autor.

4.6.2. Teor de Sílica na alimentação da concentração magnética da Mina de Fábrica

Resultados para o teor de sílica amostrado

Como realizado para o teor de ferro, a partir dos dados históricos (Figura 3.5) e utilizando o algoritmo dos mínimos quadrados recursivos apresentado na Seção 4.4, foi realizada a predição de um passo a frente do teor de sílica na alimentação da concentração magnética da Mina de Fábrica

A Tabela 4.4 apresenta os resultados dos três índices de desempenho (Seção 4.5) para diferentes valores do parâmetro do fator de esquecimento λ.

Tabela 4.4: Resultados de predição do teor de sílica amostrado da alimentação da concentração magnética

λ	RMSE	MAPE	U de Theil	%Tendência
Naive	4,7652	12,5919		
1,00	**4,3207**	**11,3442**	**0,6116**	**90,31%**
0,99	4,349	11,4158	0,6154	91,56%
0,98	4,3864	11,5076	0,6195	91,87%
0,97	4,4304	11,6259	0,6255	92,19%
0,96	4,4799	11,7474	0,6329	92,19%
0,95	4,5343	11,8639	0,6413	91,56%
0,5	8,8402	19,5781	1,5904	72,19%

Novamente, semelhante ao resultado obtido para a predição do teor de ferro, o melhor desempenho, verificado através dos três índices de desempenho, foi para o valor do fator de esquecimento $\lambda = 1$. O desempenho da predição de sílica pelo modelo AR(2), considerando o índice *U de Theil* é relativamente melhor do que o obtido para a predição do teor de ferro. Importante destacar, também, que neste cenário, o percentual de acerto da tendência apresentou oscilações, sendo o maior número de acertos obtidos para o fator de esquecimento $\lambda = 0{,}96$ e $\lambda = 0{,}97$.

As Figuras 4.22, 4.23 e 4.24 apresentam, respectivamente, o resultado da predição, a variação do erro de predição (comparado com o erro de predição do modelo *naive*) e a variação dos dois parâmetros do modelo AR(2).

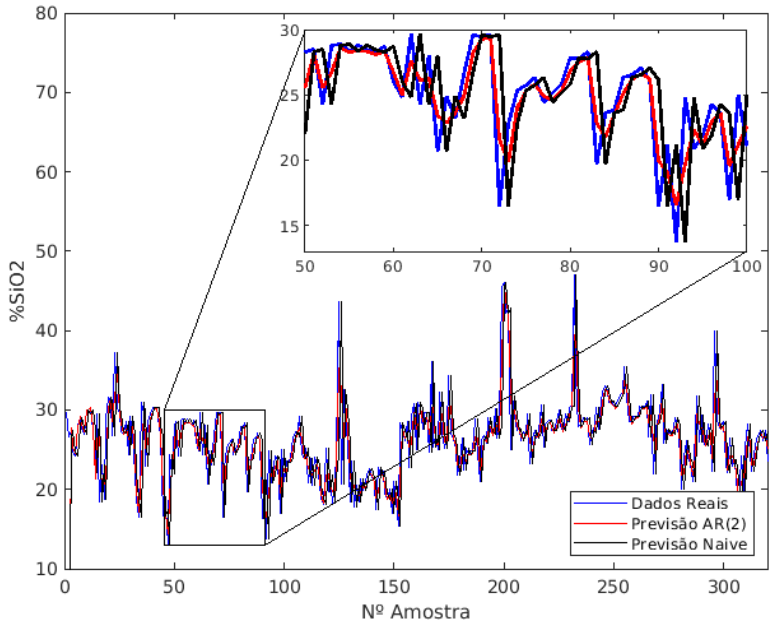

Figura 4.22: Resultado da predição de sílica amostrado na alimentação da concentração magnética - $\lambda = 1$. Fonte: elaborada pelo autor.

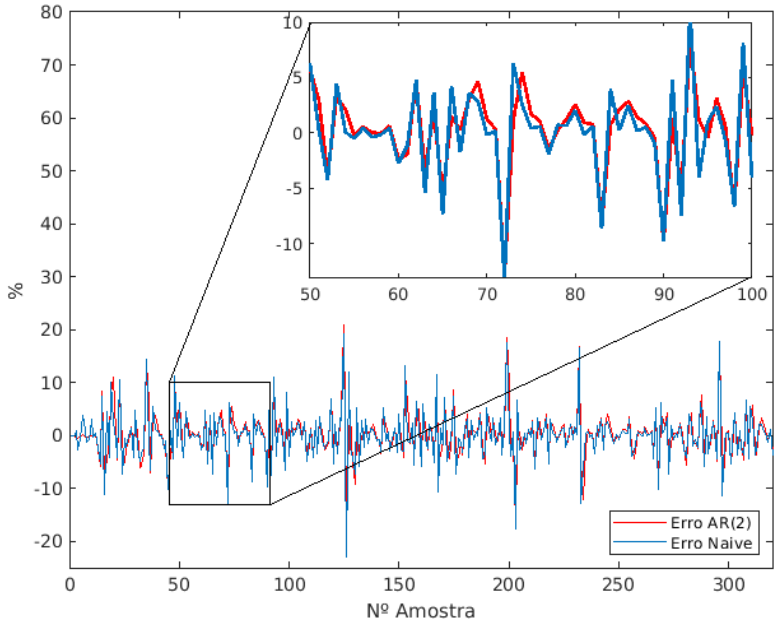

Figura 4.23: Erros da predição do sílica amostrado na alimentação da concentração magnética - $\lambda = 1$. Fonte: elaborada pelo autor.

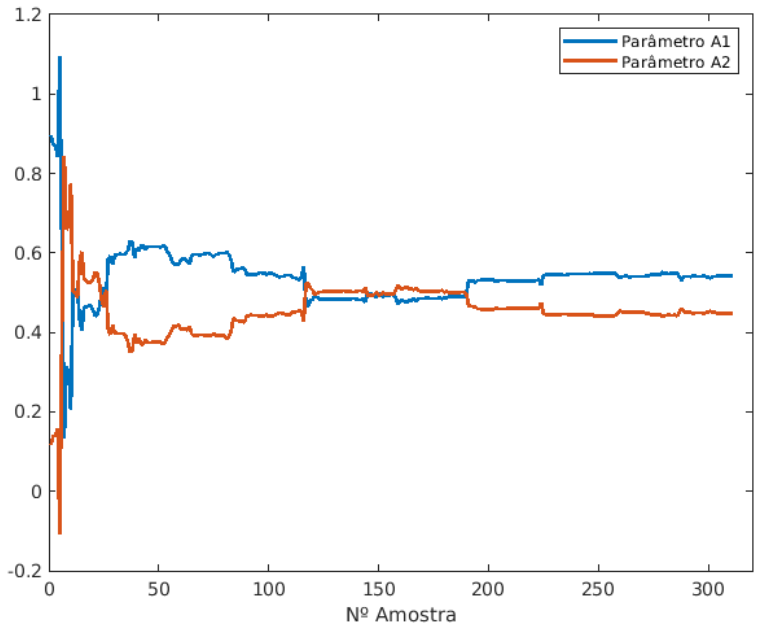

Figura 4.24: Parâmetros da predição de sílica amostrado na alimentação da concentração magnética - $\lambda = 1$. Fonte: elaborada pelo autor.

Resultados para o teor de sílica considerando amostras interpoladas

A partir dos dados históricos considerando dados interpolados (Figura 3.6) e utilizando o algoritmo dos mínimos quadrados recursivos apresentado na Seção 4.4, foi realizada a predição de um passo a frente do teor de sílica na alimentação da concentração magnética.

Assim, como apresentado para a base de dados contendo apenas os dados amostrados, a Tabela 4.5 apresenta os resultados dos três índices de desempenho (Seção 4.5) para diferentes valores do parâmetro do fator de esquecimento λ. Foi incluído também o índice de acerto da tendência da predição.

Tabela 4.5: Resultados de predição do teor de sílica interpolado da alimentação da concentração magnética

λ	RMSE	MAPE	U de Theil	%Tendência
Naive	4,2501	11,1218		
1,00	**3,89**	**10,3455**	**0,6184**	**93,33%**
0,99	3,9147	10,3947	0,621	93,61%
0,98	3,9508	10,4607	0,6255	94,44%
0,97	3,9939	10,5383	0,633	94,72%
0,96	4,0409	10,6182	0,642	94,44%
0,95	4,0902	10,6934	0,652	94,17%
0,5	10,3476	19,0154	2,1372	75,28%

Os resultados obtidos para o cenário considerando a base com dados interpolados foram muito semelhantes àqueles obtidos considerando apenas os dados amostrados, ou seja, o desempenho da predição do modelo AR(2), neste caso, é inversamente proporcional ao valor do fator de esquecimento.

Importante destacar que, apesar de o comportamento ser semelhante, considerando os resultados apresentados pelo índice *U de Theil*, os desempenhos de predição, assim como obtido para a predição dos teores de ferro, foram relativamente melhores no cenário considerando apenas os dados amostrados.

As Figuras 4.25, 4.26 e 4.27 apresentam, respectivamente, o resultado da predição, a variação do erro de predição (comparado com o erro de predição do modelo *naive*) e a variação dos dois parâmetros do modelo AR(2).

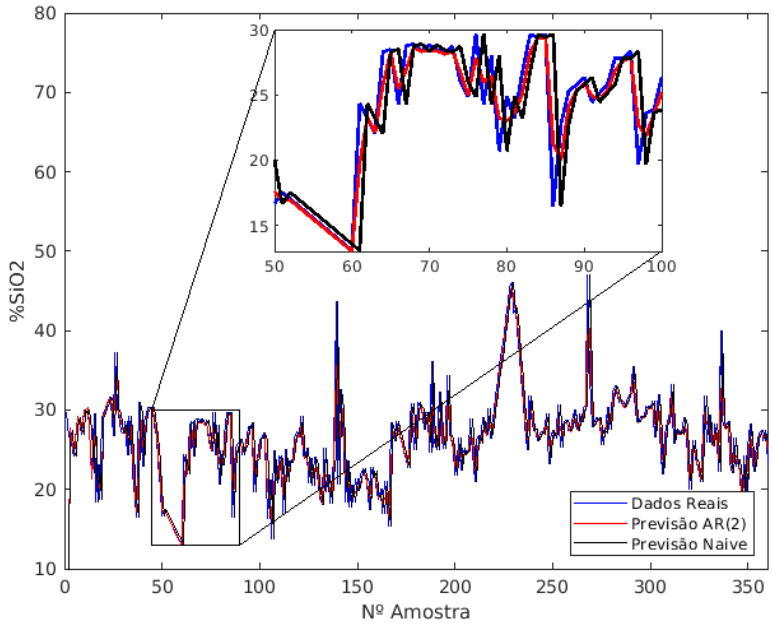

Figura 4.25: Resultado da predição de sílica interpolado na alimentação da concentração magnética - $\lambda = 1$. Fonte: elaborada pelo autor.

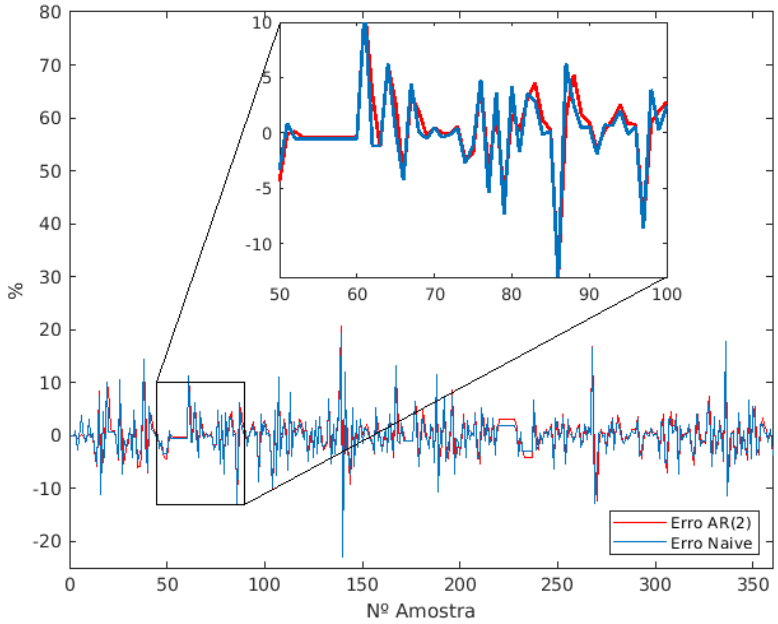

Figura 4.26: Erros da predição de sílica interpolado na alimentação da concentração magnética - $\lambda = 1$. Fonte: elaborada pelo autor.

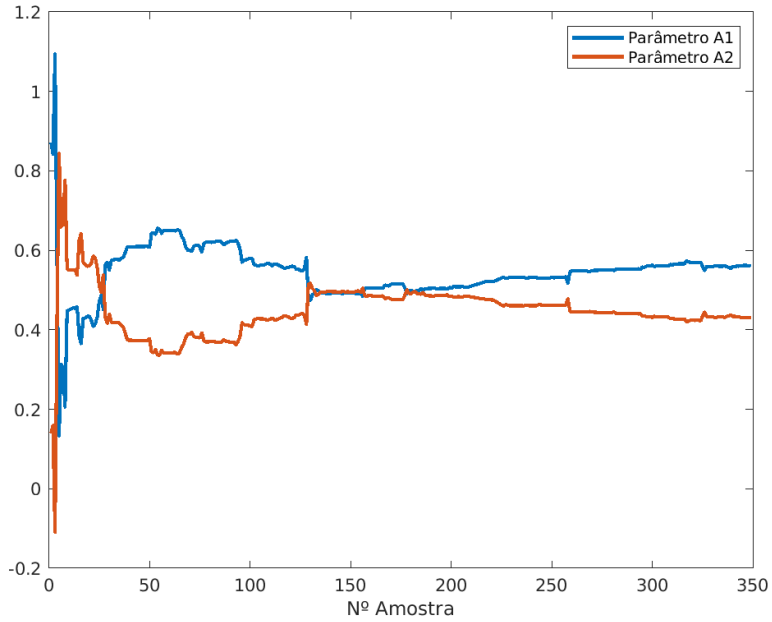

Figura 4.27: Parâmetros da predição de sílica interpolado na alimentação da concentração magnética - $\lambda = 1$. Fonte: elaborada pelo autor.

4.6.3. Teor de ferro na alimentação da flotação reversa da ITMI de Vargem Grande

Como realizado para os teores da concentração magnética da Mina de Fábrica, a partir dos dados históricos (Figura 3.7) e utilizando o algoritmo dos mínimos quadrados recursivos apresentado na Seção 4.4, foi realizada a predição de um passo a frente do teor de ferro na alimentação da flotação reversa da ITMI de Vargem Grande.

A Tabela 4.6 apresenta os resultados dos três índices de desempenho (Seção 4.5) para diferentes valores do parâmetro do fator de esquecimento λ. É possível verificar, também, o percentual de acerto da indicação da tendência.

Tabela 4.6: Resultados de predição do teor de ferro amostrado da alimentação da flotação reversa

λ	RMSE	MAPE	U de Theil	%Tendência
Naive	2,9169	5,1601		
1,00	**2,6622**	**4,733**	**0,7514**	**97,98%**
0,99	2,6758	4,7608	0,755	97,69%
0,98	2,6937	4,7931	0,7592	96,82%
0,97	2,7129	4,8293	0,7618	96,18%
0,96	2,7325	4,8657	0,764	96,82%
0,95	2,7521	4,9027	0,7662	95,95%
0,5	4,4801	7,6162	1,1233	72,54%

Novamente, semelhante ao resultado obtido para as predições dos teores da concentração magnética, o melhor desempenho, verificado através dos três índices, foi para o valor do fator de esquecimento $\lambda = 1$. Neste cenário, o percentual de acerto da tendência também foi alto, atingindo 97,98% para $\lambda = 1$ e reduzindo moderadamente para os demais valores simulados.

As Figuras 4.28, 4.29 e 4.30 apresentam, respectivamente, o resultado da predição, a variação do erro de predição (comparado com o erro de predição do modelo *naive*) e a variação dos dois parâmetros do modelo AR(2).

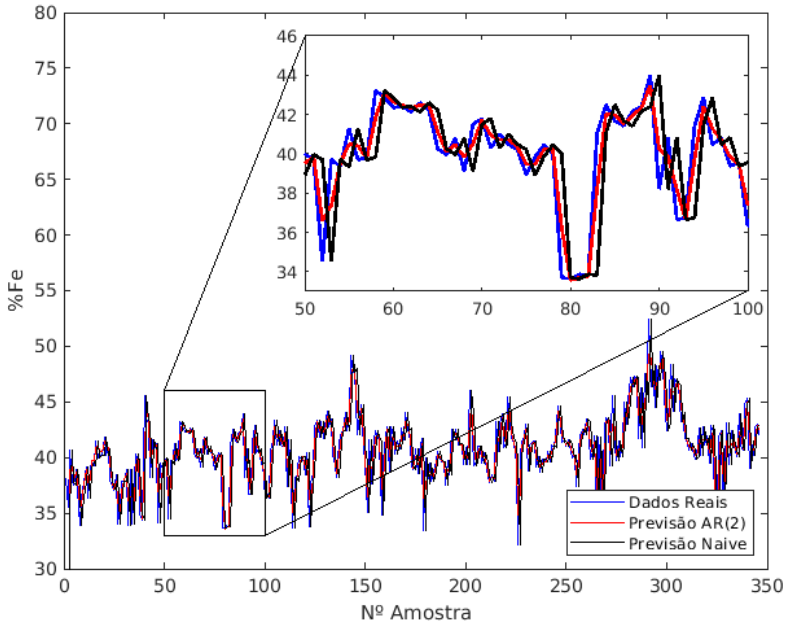

Figura 4.28: Resultado da predição de ferro amostrado na alimentação da flotação reversa - $\lambda = 1$. Fonte: elaborada pelo autor.

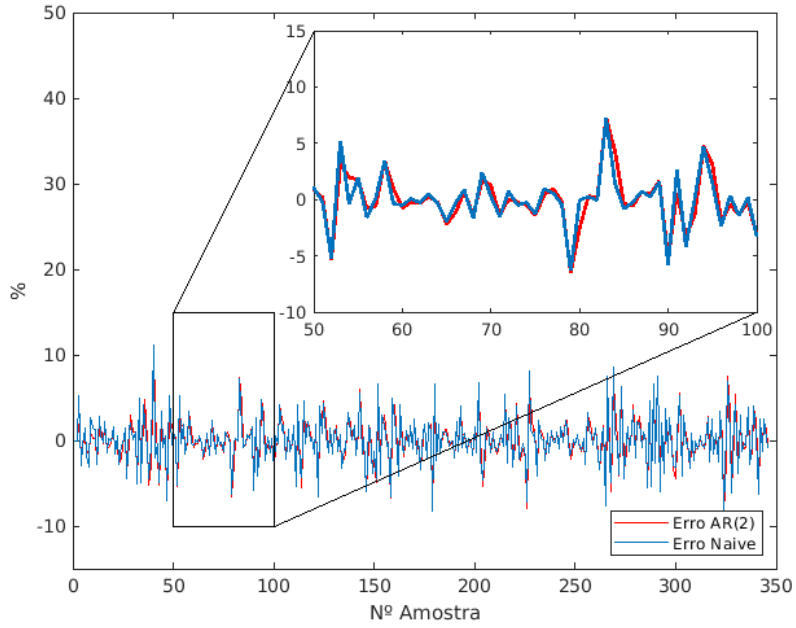

Figura 4.29: Erros da predição de ferro amostrado na alimentação da flotação reversa - $\lambda = 1$. Fonte: elaborada pelo autor.

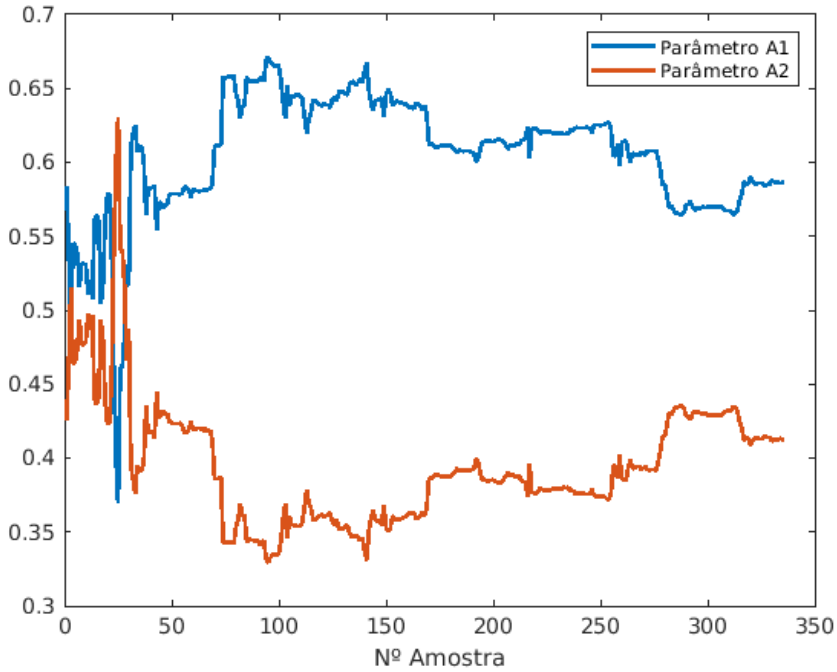

Figura 4.30: Parâmetros da predição de ferro amostrado na alimentação da flotação reversa - $\lambda = 1$. Fonte: elaborada pelo autor.

5. Labview - Implementação Prática

Neste Capítulo serão apresentados os critérios adotados para a escolha da plataforma utilizada para a implementação prática do trabalho, bem como as decisões tomadas para este desenvolvimento prático. Os resultados obtidos, ou seja, os códigos dos algoritmos desenvovidos, bem como as interfaces disponíveis para utilização, também serão apresentadas.

A implementação da solução proposta no Capítulo 4 foi realizada na estrutura existente do Labview, conforme apresentada na Seção 3.3.Utilizou-se, como base, o código apresentado no Apêndice B. Como descrito ao longo deste trabalho, a predição dos teores de ferro e sílica, dos materiais alimentados em certas etapas do processo de beneficiamento, antecipando o atraso da medida real fornecida por laboratório, pode agregar informação muito importante na tomada de decisão dos engenheiros de processo e de automação. Esta implementação foi a forma escolhida para disponibilizar automaticamente os teores preditos diretamente nos sistemas de controle das instalações de beneficiamento da empresa Vale.

A escolha pelo Labview, como solução para implementação prática deste trabalho, se deu por três motivos:

- Simplicidade de implementação - o Labview disponibiliza uma interface simples de ser utilizada. Por ser semelhante ao Simulink (da Mathworks), que é largamente utilizado no meio acadêmico, não demanda muitas horas de dedicação e aprendizado para início de sua utilização;

- Praticidade - pelo fato de já existir um ambiente de desenvolvimento do Labview, bem como controladores industriais distribuídos, conforme apresentado na Seção 3.3, a integração da solução proposta com os sistemas de controle dos processos industriais torna-se muito mais prática de ser realizada;

- Integração com Matlab - o Labview possui um módulo específico, o *mathscript*, que permite utilizar diretamente partes do código (em extensão .m) desenvolvido no ambiente do Matlab, diretamente na interface do Labview, simplificando a necessidade de recodificação.

A implementação foi realizada no servidor do Labview, localizado no *datacenter* da Mina de Conceição, conforme representado na Figura 3.8. É possível executar o código de predição dos teores tanto no próprio servidor, como realizado durante os testes, quanto definir por executa-lo diretamente nos controladores industriais. Caso opte-se por executar o código diretamente nos controladores, os parâmetros de entrada devem ser substituídos por constantes, visto que a execução é autônoma e não possui interface para inserir valores nos parâmetros.

Durante a implementação prática da solução, optou-se por desenvolver duas formas distintas de realizar a predição dos teores. A primeira delas, semelhante ao código que foi desenvolvido no Matlab, e apresentado no Apêndice B, possibilita que sejam importados dados históricos previamente armazenados. A segunda forma implementada realiza a leitura dos dados fornecidos pelo laboratório, diretamente do sistema PIMS. Os dados são armazenados e a cada

nova amostra obtida é realizada uma iteração para predição um passo a frente. Nas seções a seguir, estas duas formas, referenciadas respectivamente como Implementação Prática *Offline* e Implementação Prática *Online*, serão descritas de forma mais detalhada.

5.1. Aplicação usando dados *offline*

A solução *offline* foi implementada com o objetivo de permitir que os engenheiros de processo e automação realizem a predição dos teores a partir de dados históricos previamente armazenados. Essa situação pode ser necessária, caso ocorra algum problema com a interface de leitura dos dados do LIMS através da interface com o PIMS. As informações geradas em laboratório podem ser armazenadas diretamente, sem necessidade de realizar historiamento através do sistema PIMS. Esta aplicação pode ser utilizada, também, para a realização de testes ou de validação de melhorias.

Na aplicação *offline*, o usuário deve inserir 5 parâmetros para que seja possível executar o código, são eles:

- Diretório - informar o caminho completo do arquivo, contendo os dados, previamente registrados, do teor para o qual pretende-se realizar a predição;
- N0 - informar o número de amostras que serão usadas inicialmente, para definir os primeiros valores dos parâmetros do modelo autorregressivo;
- n - informar a ordem do modelo autorregressivo, que pretende-se utilizar para a realização da predição;
- Lambda - informar o parâmetro do fator de esquecimento, a ser utilizado no cálculo realizado pelo algoritmo dos mínimos quadrados recursivos;
- *Update Time* - Este parâmetro deve ser utilizado caso opte-se por acompanhar a evolução do algoritmo, a medida que as iterações forem ocorrendo. A cada novo valor lido, do arquivo com os dados previamente registrado, um novo valor de predição será informado. Caso opte-se por visualizar diretamente o último valor da predição, este parâmetro deve ser preenchido com o valor 1 (em milissegundos).

Inicialmente, os N0 primeiros valores históricos do teor são carregados, para que sejam calculados os primeiros valores dos parâmetros do modelo autorregressivo, e a primeira predição de um passo a frente é realizada. A partir desse ponto, a cada *Update Time*, uma nova iteração é realizada, um novo valor é lido do arquivo histórico e um novo valor do teor predito é calculado. A cada valor de predição, um *flag* sinaliza se o comportamento apresenta tendência crescente ou decrescente. A Figura 5.1 representa a interface que o usuário utiliza no ambiente do Labview no servidor desta aplicação.

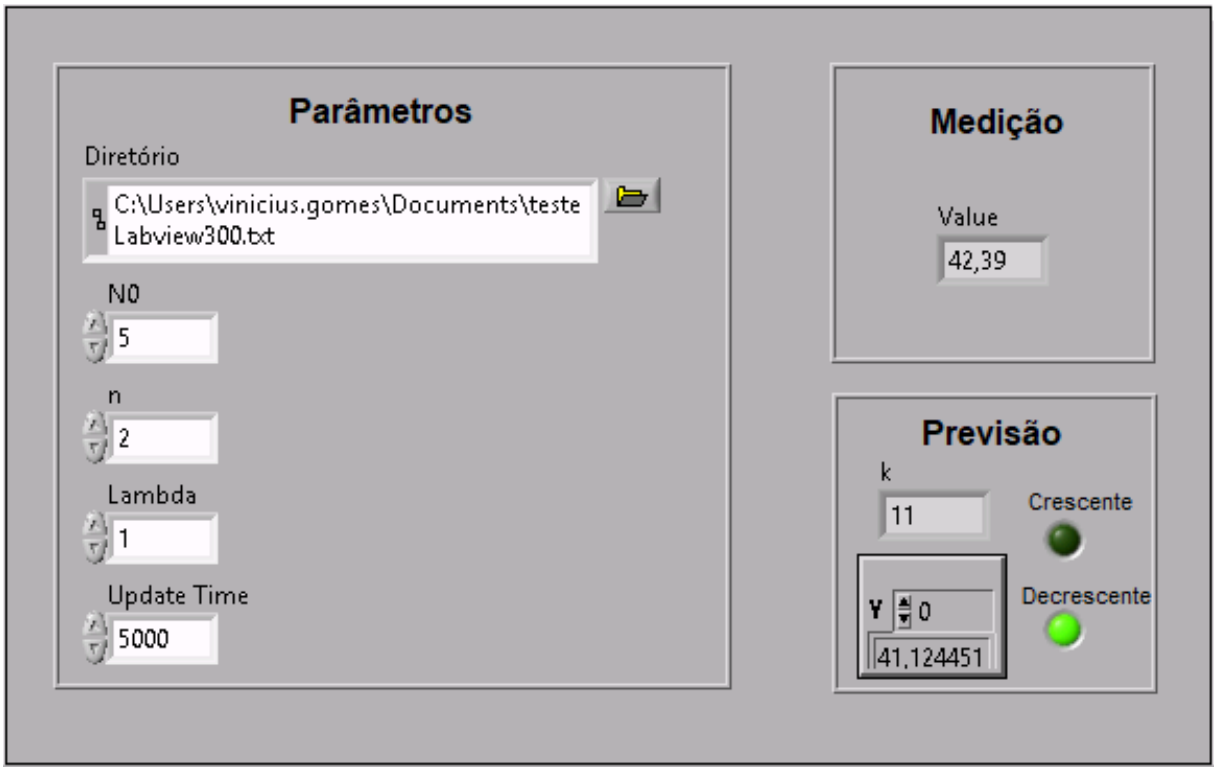

Figura 5.1: Interface da aplicação usando dados *offline*. Fonte: elaborada pelo autor.

Como descrito, o Labview possui um módulo específico para execução de códigos desenvolvidos no ambiente do Matlab. Este módulo é muito útil na implementação deste trabalho, porém, algumas funções do Matlab mais complexas não podem ser executadas no mesmo. Nesta implementação, a função *forecast* do Matlab não pode ser executada neste módulo e, portanto, teve de ser implementada utilizando funções específicas do Labview. Algumas funções de manipulação de matrizes também tiveram que ser desenvolvidas a parte, visto que tais manipulações eram necessárias para preparar os dados a serem utilizados nas funções da biblioteca própria do Labview. A implementação do código em questão pode ser verificada na Figura 5.2.

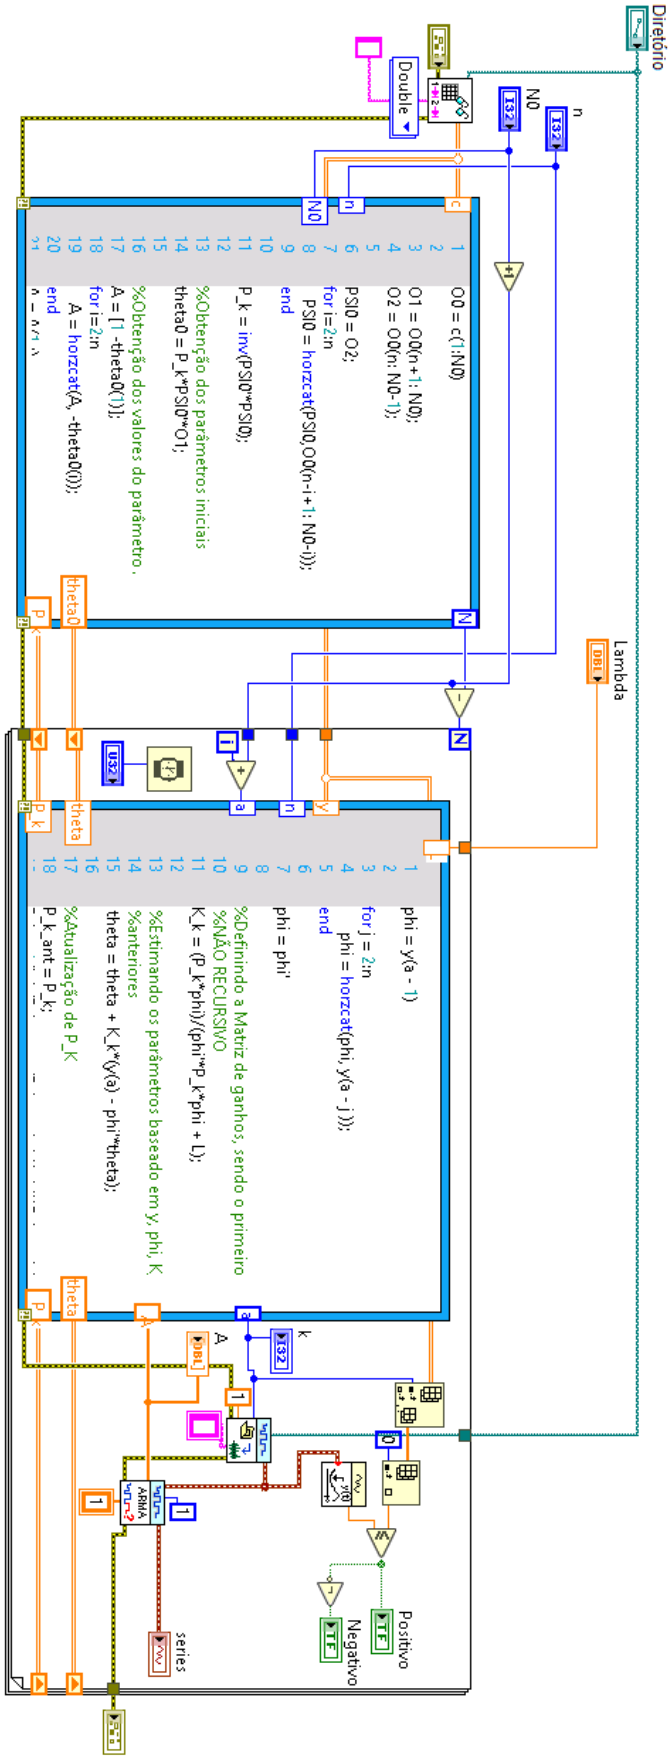

Figura 5.2: Código Labview da aplicação usando dados *offline*. Fonte: elaborada pelo autor.

5.2. Aplicação usando dados *online*

A solução *online* foi implementada com o objetivo de permitir que os engenheiros de processo e automação obtenham a predição do teor um passo a frente, baseado na última medida realizada pelo laboratório, em tempo real. Fazendo o *download* deste código para o controlador industrial do Labview e substituindo os parâmetros por constantes, permite que o mesmo execute de forma recorrente e forneça a informação da predição diretamente para os CLPs do sistema de controle da planta em que o mesmo for utilizado.

Na implementação *online*, o usuário deve inserir 4 parâmetros para que seja possível executar o código ou, substitui-los por constantes, caso opte pela execução no controlador industrial. São eles:

- Tag - informar o tag do PIMS, que registra os dados do teor, para o qual pretende-se realizar a predição;
- N0 - informar o número de amostras que serão usadas inicialmente, para definir os primeiros valores dos parâmetros do modelo autorregressivo;
- n - informar a ordem do modelo autorregressivo, que pretende-se utilizar para a realização da predição;
- Lambda - informar o parâmetro do fator de esquecimento, a ser utilizado no cálculo realizado pelo algoritmo dos mínimos quadrados recursivos;

Neste cenário não é necessário parametrizar o *Update Time*, visto que as iterações são realizadas a medida que um novo valor é lido do PIMS.

Inicialmente, os N0 primeiros valores do teor lidos através do PIMS são armazenados, para que sejam calculados os primeiros valores dos parâmetros do modelo autorregressivo. A partir desse ponto, a cada novo valor lido do PIMS, uma nova iteração é realizada e um novo valor do teor predito é calculado. A cada valor de predição, um *flag* sinaliza se o comportamento apresenta tendência positiva ou negativa. A Figura 5.3 representa a interface com uma predição com tendência negativa. Já a Figura 5.4 representa a interface com uma predição com tendência positiva.

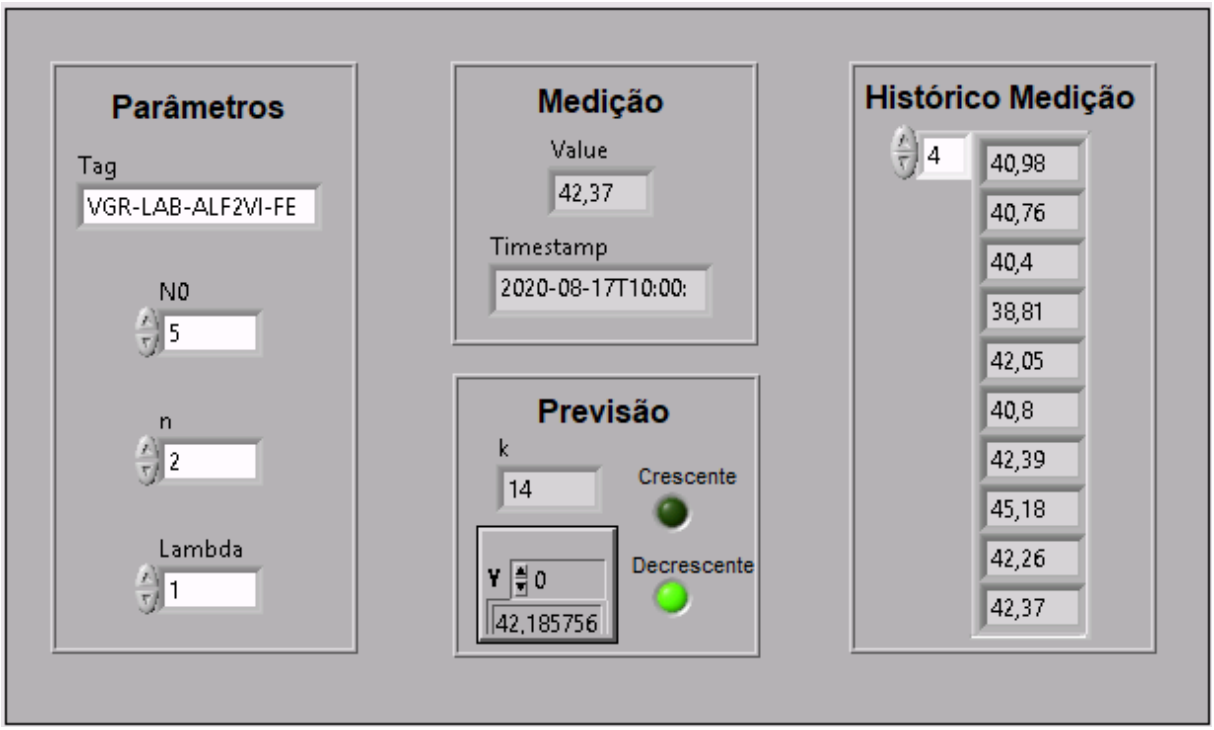

Figura 5.3: Interface da aplicação usando dados *online* - tendência negativa Fonte: elaborada pelo autor.

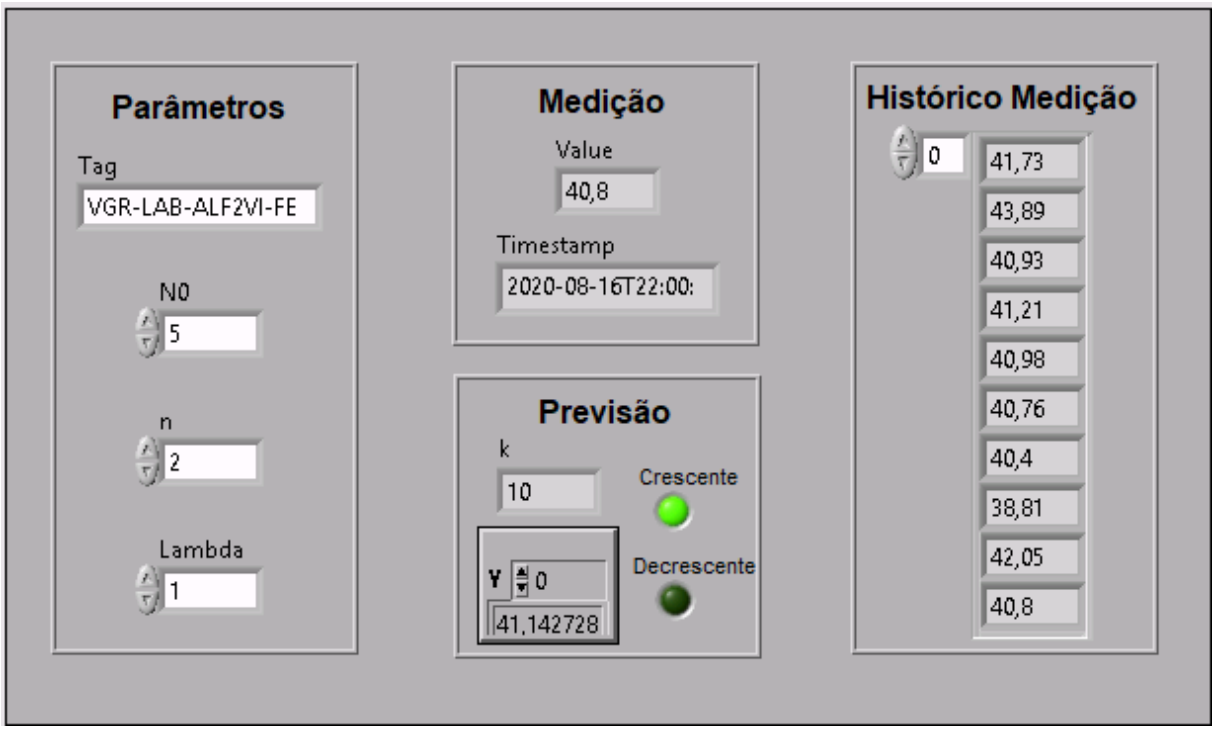

Figura 5.4: Interface da aplicação usando dados *online* - tendência positiva Fonte: elaborada pelo autor.

Para a solução *online* foram implementados três *loops* distintos no código do Labview. A comunicação, ou seja, transferência de dados entre estes *loops*, é realizada através de *Notifiers*. Neste cenário, os *loops* consumidores só iniciam sua execução após receberem uma notificação com a informação que necessitam, enviada pelo *loop* produtor:

- *Loop* 1 (produtor) - responsável por realizar a leitura dos dados do PIMS;
- *Loop* 2 (consumidor) - responsável por carregar os primeiros N0 valores lidos do PIMS e gerar os valores iniciais dos parâmetros do modelo autorregressivo;
- *Loop* 3 (consumidor) - responsável por receber os valores iniciais dos parâmetros do *Loop 2* e executar as iterações, fornecendo um valor do teor predito a cada uma delas.

O *Loop* 1, ou *Loop* produtor, utiliza um *Virtual Instrument* (VI) previamente desenvolvido pela equipe de Otimização da Gerência de Engenharia de Automação dos corredores Sul/Sudeste da Vale. Este VI realiza a comunicação com o sistema PIMS PI, através de interface *Web API*, e necessita ser parametrizado apenas com o TAG contendo a informação do teor a ser lido. Um dos benefícios do projeto de atualização dos sistemas PIMS, descrito na Seção 3.1.3, pode ser verificado nesta situação. Como todos os servidores das unidades da Vale em Minas Gerais foram centralizados em um par de servidores redundantes do PI, este VI desenvolvido pode ser utilizado para leitura de dados históricos de qualquer uma destas plantas de produção, sem que seja necessário nenhum tipo de adequação.

O período de amostragem (em milissegundos) para leitura do PI pode ser parametrizado no *loop* produtor. A cada valor lido, é verificado se este representa um valor atual do teor (amostra nova de laboratório), ou se foi realizada a leitura de um valor já registrado anteriormente. Essa verificação é realizada comparando-se tanto o *timestamp* da nova amostra, quanto o seu valor, com os valores obtidos para a última leitura válida. Para ser considerada uma amostra nova, é necessário que ambas as comparações apresentem valores diferentes. A Figura 5.5 representa o VI utilizado para comunicar com o PI. Já a Figura 5.6 representa o *loop* produtor.

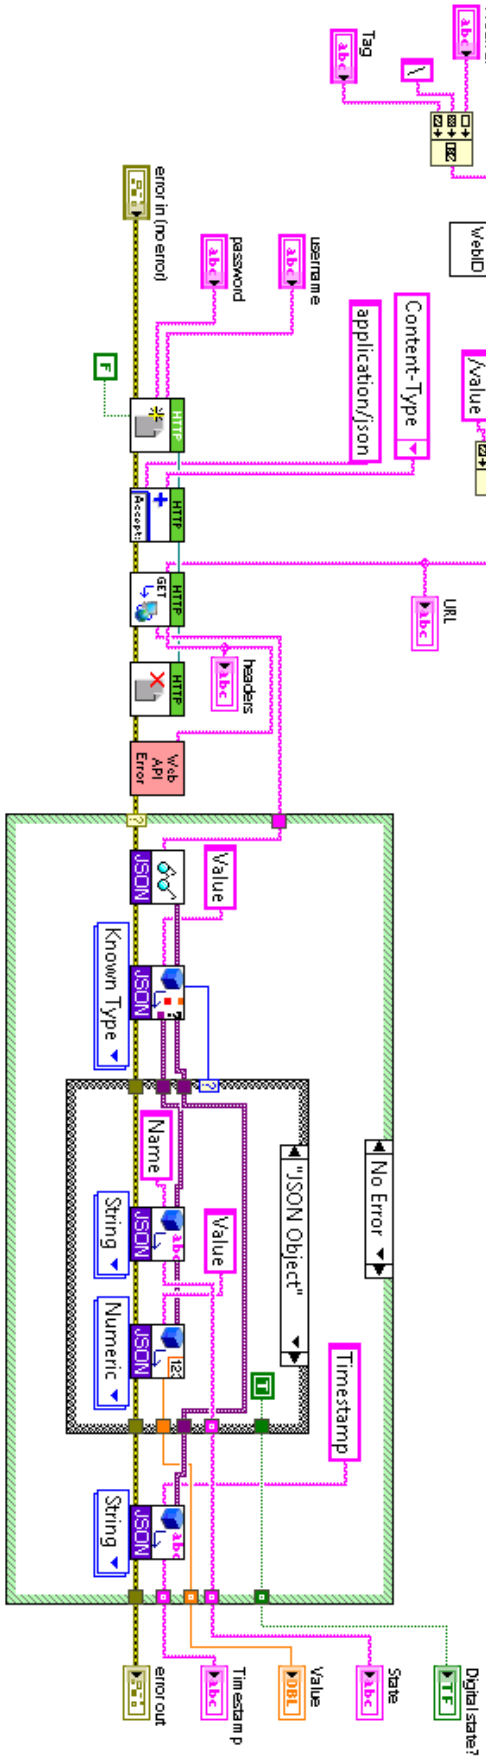

Figura 5.5: VI utilizado para comunicar com o sistema PIMS PI. Fonte: Gerência de Engenharia de Automação dos corredores Sul/Sudeste.

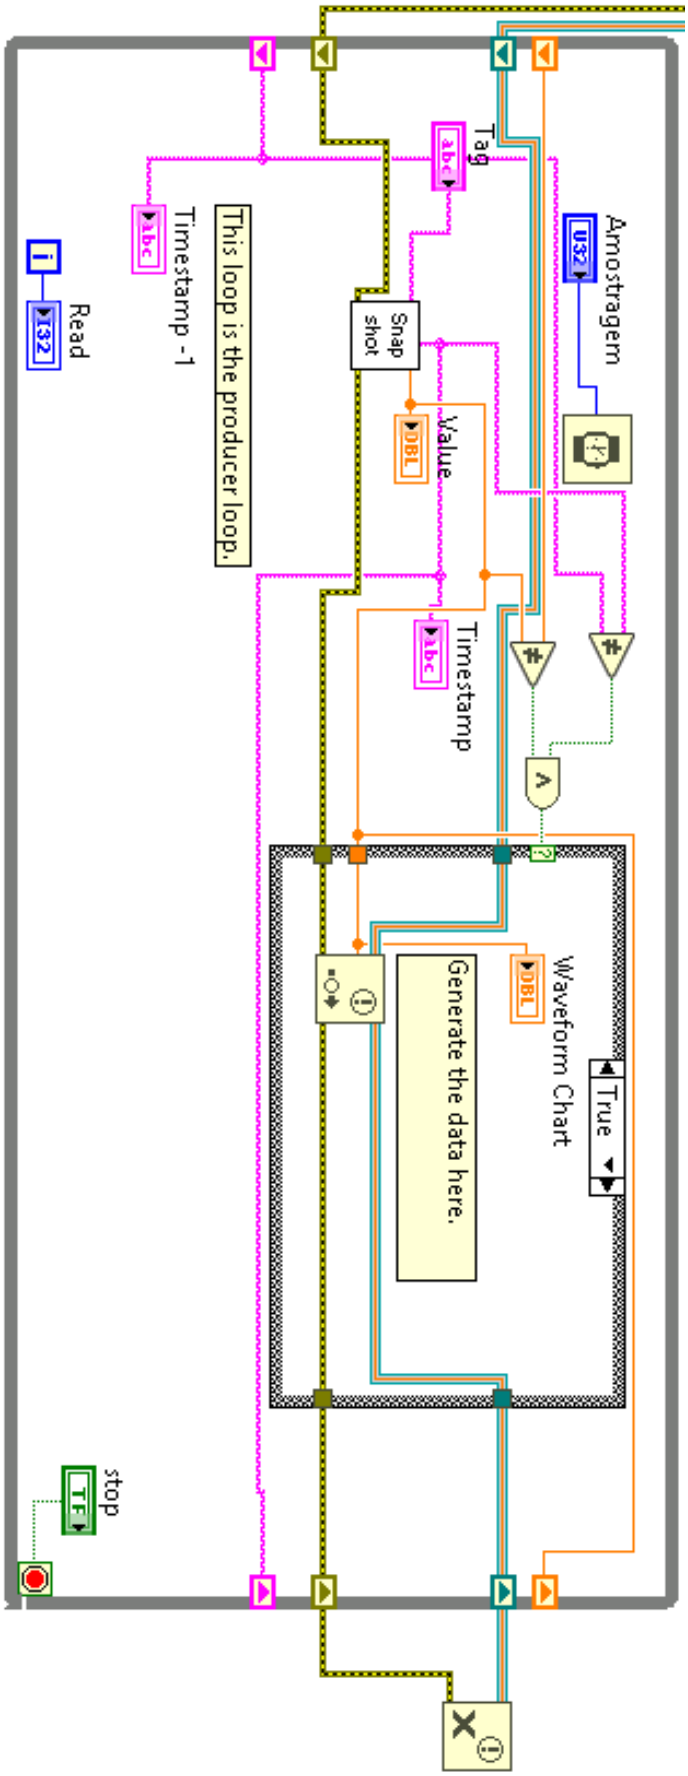

Figura 5.6: *Loop* responsável pela leitura dos valores do PIMS PI. Fonte: elaborado pelo autor.

Os *loops* consumidores utilizam o módulo *mathscript* para execução do código previamente desenvolvido no ambiente Matlab. Assim como na implementação *offline*, algumas funções do Matlab não podem ser executadas neste módulo, e devem ser implementadas diretamente com as funções disponíveis no Labview. As Figuras 5.7 e 5.8 representam os *loops* consumidores, responsáveis por gerar os parâmetros iniciais do modelo autorregressivo, e por realizar as predições do teor, respectivamente.

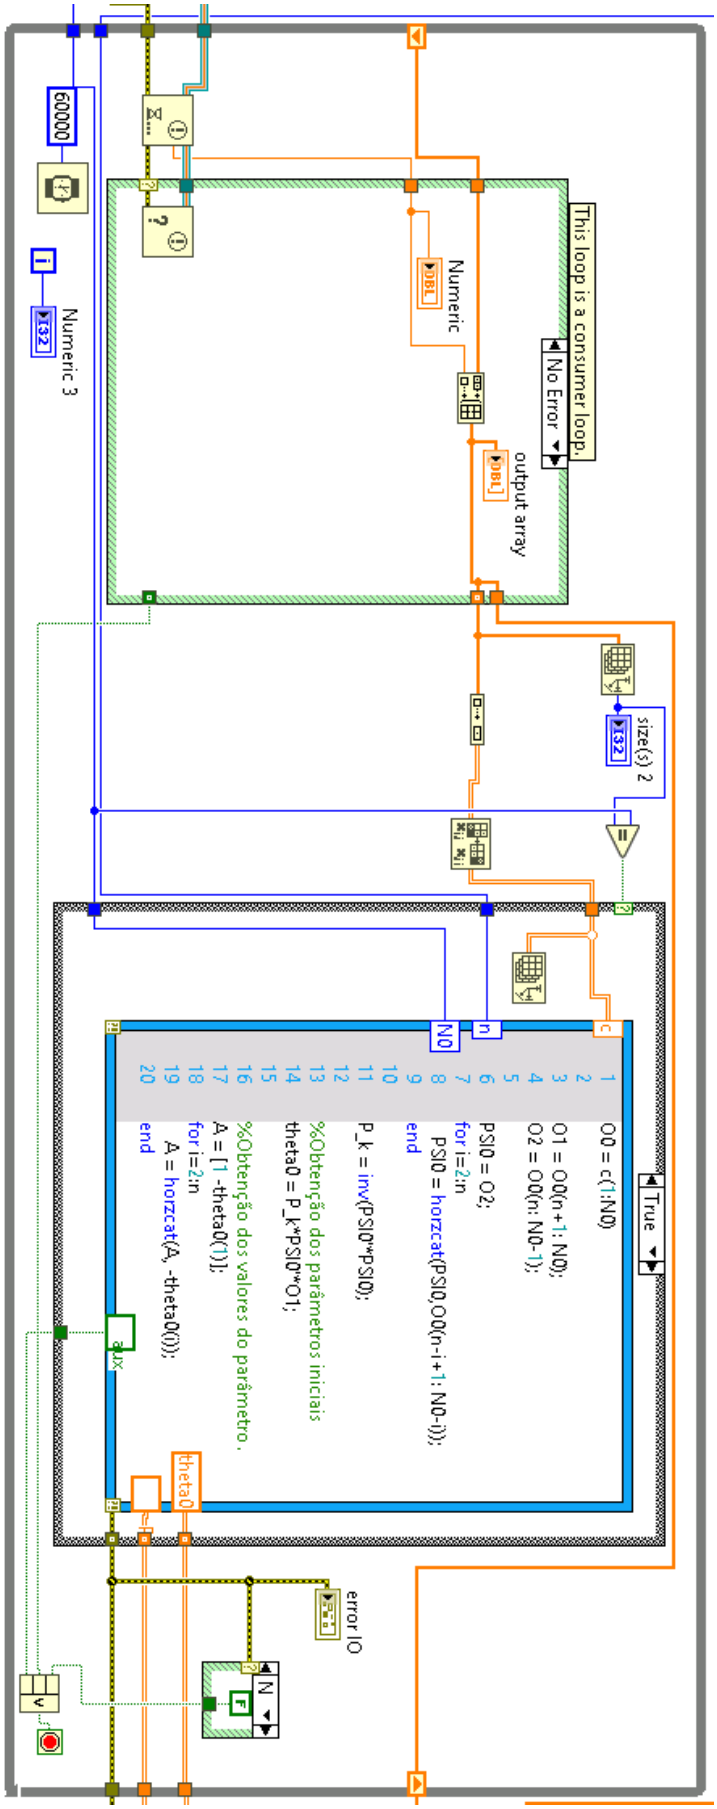

Figura 5.7: *Loop* utilizado para gerar os primeiros parâmetros do modelo AR(2). Fonte: elaborado pelo autor.

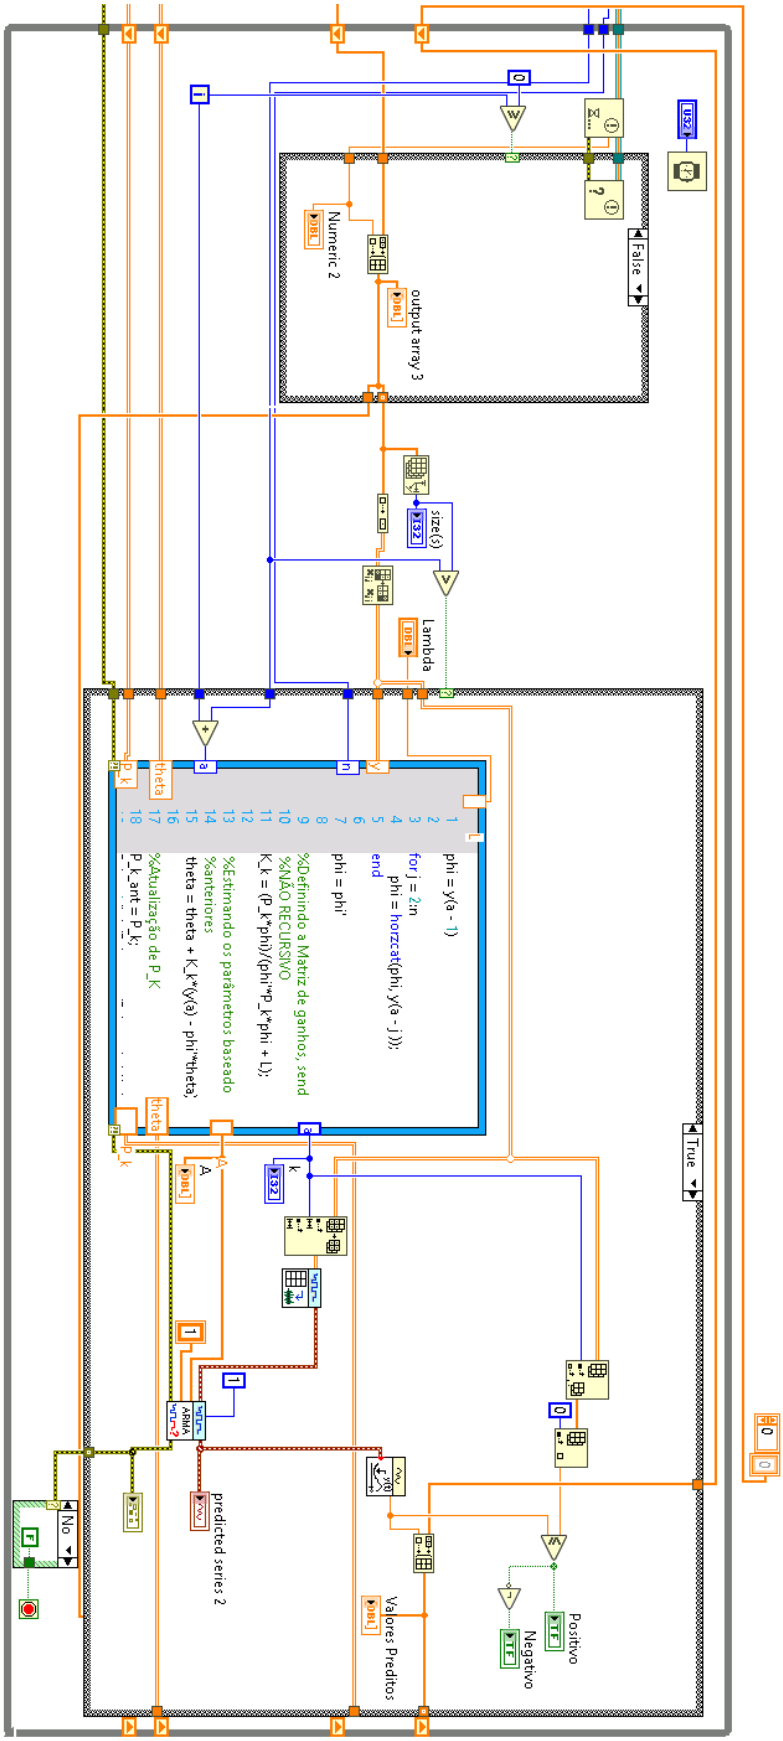

Figura 5.8: *Loop* responsável pelas iterações e predição do teor. Fonte: elaborado pelo autor.

As aplicações desenvolvidas e apresentadas já estão disponíveis para utilização e predição dos teores dos processos em questão. Em função da suspensão de operação das minas dos corredores Sul/Sudeste da Vale, determinadas pelo Ministério Público, a planta da Mina de Fábrica ainda não retornou sua operação e a ITMI de Vargem Grande está retornando sua operação de forma parcial. Apesar de a ITMI de Vargem Grande já estar com algumas linhas em operação, a mesma possui um sistema de medição online do teor, conforme apresentado anteriormente. Dessa forma, ainda não foram registradas possíveis melhorias nos controles de tais processos, em função da predição, até a conclusão da elaboração desta dissertação.

6. Conclusões e Sugestões de Trabalhos Futuros

6.1. Conclusões

Neste trabalho, foi apresentada a metodologia para estimação de modelos de predição de séries temporais, baseada em modelos paramétricos lineares. As etapas para definição dos modelos, por meio das análises de estacionariedade, autocorrelação e autocorrelação parcial foram demonstradas ao longo deste desenvolvimento.

A metodologia foi aplicada para estimação de modelos usados predição dos teores de ferro e sílica, dos materias alimentados em etapas de dois processos distintos de concentração de finos - concentração magnética e flotação reversa. Através das análises realizadas, foi definido o modelo autorregressivo de ordem 2. Por meio do algoritmo dos mínimos quadrados recursivos, foi realizada a predição um passo a frente dos teores. Foram usados dados reais de duas plantas de beneficiamento mineral distintas, Mina de Fábrica e ITMI de Vargem Grande, cada uma contendo um processo de beneficiamento específico, concentração magnética e flotação reversa, respectivamente.

Por fim, a solução proposta foi implementada na plataforma do Labview, disponível nas instalações de beneficiamento mineral da Vale no estado de Minas Gerais. Duas aplicações distintas, da solução proposta, foram criadas e disponibilizadas para os engenheiros de processo e automação. A primeira, na qual utilizam-se dados previamente registrados das informações disponibilizadas por laboratório, ou *offline*, pode ser utilizada sem a necessidade de inteface do sistema de laboratório (LIMS) com o sistema de historiamento da planta (PIMS), ou em casos de realização de testes e validação de estratégias em específico. A segunda, *online*, na qual utilizam-se dados lidos do sistema PIMS, foi desenvolvida para executar diretamente em comunicação com os sistemas de automação, fornecendo as informações de predição para serem utilizadas nas estratégias de controle específicas dos processos.

Durante o desenvolvimento deste trabalho, algumas questões foram levantadas, que pautaram o desenvolvimento e algumas discussões:

- Modelos Autorregressivos são suficientes para realizar a indicação de tendência ascendente ou descendente, dos teores de ferro e sílica dos materiais alimentados em processos de beneficiamento de finos, em escala industrial?

  Conforme demonstrado na Seção 4.6, o modelo autorregressivo escolhido, AR(2), demonstrou bom desempenho na indicação da tendência ascendente ou descendente nos diversos cenários testados. Para a predição do teor de ferro, seja através dos dados amostrados ou interpolados, tanto para o processo de concentração magnética, quanto para a flotação reversa, o percentual de acerto obtido foi superior a 95%, para todas as simulações em que o fator de esquecimento esteve dento da faixa indicada, entre 0,95 e 1,00. Para a predição do teor de sílica, nas mesmas condições, o percentual de acerto obtido foi superior a 90%.

Estes resultados demonstram que o modelo é suficiente para a indicação das tendências.

- Modelos Autorregressivos são suficientes para realizar a predição um passo a frente dos teores de ferro e sílica dos materiais alimentados em tais processos?

  Foi possível verificar, também através dos resultados apresentados na Seção 4.6, que o modelo AR(2) apresenta desempenho superior ao modelo *naive* na predição um passo a frente dos teores. Os erros do modelo, apesar de ainda não serem irrelevantes, podem ser considerados como variação de amplitude das amostras, visto que a tendência da predição demonstrou acerto em mais de 95% dos casos. Portanto, estes resultados demonstram que o modelo AR(2) desempenha um bom papel na predição um passo a frente dos teores.

- A predição dos teores de diferentes instalações pode ser representada por modelos autorregressivos com mesma ordem?

  Conforme pode ser verificado na Seção 4.6.3, o modelo autorregressivo de mesma ordem - AR(2) - que havia sido utilizado para representar o comportamento temporal dos teores de ferro e sílica, no processo de concentração magnética de Mina de Fábrica, também foi utilizado na representação dos teores da flotação reversa da ITMI de Vargem Grande. Importante ressaltar que apenas a ordem dos modelos autorregressivos é a mesma, visto que os mesmos são dinâmicos, com obtenção dos valores dos parâmetros a cada nova iteração.

- A utilização de dados interpolados, quando da ocorrência de amostras faltantes, gera alterações positivas ou negativas na estimação do modelo?

  Conforme resultados obtidos nas Seções 4.6.1 e 4.6.2, foi possível verificar que os desempenhos das predições, avaliadas através do método U de Theil (Seção 4.5.3), não demonstraram variações significativas entre os dados amostrados ou interpolados. No geral, o desempenho na predição utilizando dados amostrados foi cerca de 1,5% melhor.

- É possível implementar um sistema que forneça automaticamente as informações de predição e tendências dos teores para os sistemas de controle dos respectivos processos?

  Como apresentado no Capítulo 5, foi possível implementar uma aplicação que fornceça automaticamente as informações de predição e tendência dos teores, para os sistemas de controle dos processos específicos. Este resultado, possibilita que estas novas informações possam ser utilizadas nas melhorias das estratégias de controle dos processos.

6.2. Sugestões de Trabalhos Futuros

Como trabalhos futuros são sugeridos:

- Definir, junto às equipes de laboratório, quais outras informações, fornecidas pelas análises físicas (granulometrias) e químicas (demais teores componentes do material, como alumínio, cálcio, manganês ou potássio), podem ser utilizados para inferir os teores principais de interesse (ferro e sílica). Após definidas tais informações, as mesmas poderiam ser utilizadas como entradas exógenas no modelo autorregressivo;

- Utilizar informações do modelo de blocos geológico, por meio de posicionamento aproximado da frente de lavra (informação existente nos sistemas de despacho) e, por meio de rastreamento, identificar a fonte do material sendo alimentado nos processos de concentração. Esta informação também pode ser utilizada como entrada exógena no modelo autorregressivo;

- Utilizar outras técnicas de predição de séries temporais, como modelos baseados em redes neurais ou *machine learning*;

- Implementar estratégias de controle dos processos de concentração com as informações de predição e tendência, fornecidas pelo trabalho em questão, e avaliar possíveis melhorias de desempenho.

Referências Bibliográficas

AGUIRRE, L. A. *Introdução à identificação de sistemas–Técnicas lineares e não-lineares aplicadas a sistemas reais*. Editora UFMG, 2004.

ANDERSON, C. *Flotation Equipment and Processes*. Relatório técnico, Kroll Institute for Extractive Metallurgy - Colorado School of Mines, 07 2017.

BOX, G. E., JENKINS, G. M., REINSEL, G. C., et al.. *Time series analysis: forecasting and control*. John Wiley & Sons, 2015.

CHAI, T., DRAXLER, R. R. "Root mean square error (RMSE) or mean absolute error (MAE)?–Arguments against avoiding RMSE in the literature", *Geoscientific model development*, v. 7, n. 3, pp. 1247–1250, 2014.

CHEN, L., REN, N., XIONG, D. "Experimental study on performance of a continuous centrifugal concentrator in reconcentrating fine hematite", *International journal of mineral processing*, v. 87, n. 1-2, pp. 9–16, 2008.

DA SILVA, M. T. *Identificação de Sistemas usando Modelos Hammerstein e Wiener utilizando Método do Relé*. Tese de Mestrado, Universidade Federal de Campina Grande, 2014.

DICKEY, D. A., FULLER, W. A. "Distribution of the estimators for autoregressive time series with a unit root", *Journal of the American statistical association*, v. 74, n. 366a, pp. 427–431, 1979.

FAN, J., YAO, Q. *Nonlinear time series: nonparametric and parametric methods*. Springer Science & Business Media, 2008.

GE, W., ENCINAS, A., ARAUJO, E., et al.. "Magnetic matrices used in high gradient magnetic separation (HGMS): A review", *Results in physics*, v. 7, pp. 4278–4286, 2017.

GUO, W. W. "A novel application of neural networks for instant iron-ore grade estimation", *Expert Systems with Applications*, v. 37, n. 12, pp. 8729–8735, 2010.

HAMILTON, J. D. *Time series analysis*, v. 2. Princeton New Jersey, 1994.

HODOUIN, D. “Methods for automatic control, observation, and optimization in mineral processing plants”, *Journal of Process Control*, v. 21, n. 2, pp. 211 – 225, 2011. ISSN: 0959-1524. Special Issue on Automation in Mining, Minerals and Metal Processing.

HOLMES, R., LU, L. “Introduction: overview of the global iron ore industry”. Em: *Iron Ore*, Elsevier, pp. 1–42, 2015.

HUANG, Z., CHALABI, Z. “Use of time-series analysis to model and forecast wind speed”, *Journal of Wind Engineering and Industrial Aerodynamics*, v. 56, n. 2-3, pp. 311–322, 1995.

ISERMANN, R., MÜNCHHOF, M. *Identification of dynamic systems: an introduction with applications*. Springer Science & Business Media, 2010.

KAMAL, L., JAFRI, Y. Z. “Time series models to simulate and forecast hourly averaged wind speed in Quetta, Pakistan”, *Solar Energy*, v. 61, n. 1, pp. 23–32, 1997.

KITAGAWA, G., GERSCH, W. “A smoothness priors time-varying AR coefficient modeling of nonstationary covariance time series”, *IEEE Transactions on Automatic Control*, v. 30, n. 1, pp. 48–56, 1985.

KUMRAL, M. “Grade control in multi-variable ore deposits as a quality management problem under uncertainty”, *International Journal of Quality & Reliability Management*, 2015.

LU, L. *Iron Ore: Mineralogy, Processing and Environmental Sustainability*. Elsevier, 2015.

MAHMOUDABADI, H., IZADI, M., MENHAJ, M. B. “A hybrid method for grade estimation using genetic algorithm and neural networks”, *Computational Geosciences*, v. 13, n. 1, pp. 91–101, 2009.

MARÉ, E., BEVEN, B., CRISAFIO, C. “Developments in nonmagnetic physical separation technologies for hematitic/goethitic iron ore”. Em: *Iron Ore*, Elsevier, pp. 309–338, 2015.

MARQUES, M. *Concentração Magnética Aplicada a Minério de Ferro - PTP-000749, Rev. 05*. Vale - Diretoria de Engenharia e Gestão de Ativos, 2020.

MARQUES, M. *Flotação Minério de Ferro - PTP-000736, Rev. 04*. Vale - Diretoria Planejamento e Desenvolvimento Ferrosos, 2016.

MINERCONSULT, S. L. *Projeto Vargem Grande Itabiritos - S1066 - Nº VALE: 2020VG-P-00001*. Projeto Vargem Grande Itabiritos, 2012.

MONTGOMERY, D. C., JENNINGS, C. L., KULAHCI, M. *Introduction to time series analysis and forecasting*. John Wiley & Sons, 2015.

NOUNOU, M., BAKSHI, B., WALCZAK, B. "Multiscale methods for denoising and compression", *Wavelets in Analytical Chemistry*, pp. 119–150, 2000.

PATEL, A. K., CHATTERJEE, S., GORAI, A. K. "Development of machine vision-based ore classification model using support vector machine (SVM) algorithm", *Arabian Journal of Geosciences*, v. 10, n. 5, pp. 107, 2017.

ROBERTS, S., OSBORNE, M., EBDEN, M., et al.. "Gaussian processes for time-series modelling", *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, v. 371, n. 1984, pp. 20110550, 2013.

SABORIDO, D. *Seminário Flotação*. Vale/DIFL - Complexo Vargem Grande - Gerência de Operação ITMI-VGR, September 2014.

SMITH, B. L., WILLIAMS, B. M., OSWALD, R. K. "Comparison of parametric and non-parametric models for traffic flow forecasting", *Transportation Research Part C: Emerging Technologies*, v. 10, n. 4, pp. 303–321, 2002.

SÖDERSTRÖM, T., STOICA, P. *System identification*. Prentice-Hall International, 1989.

TASDEMIR, A. "Analysis of chromite processing plant data by first order autoregressive model", *Physicochemical Problems of Mineral Processing*, v. 49, 2013.

Relatório Técnico RT-CVR-07019-003 Rev. B. Vale/DIFL/GAEEL- Gerência de Engenharia Elétrica e Automação, 2007.

Relatório Técnico RL-1410HH-J-33802 - Estudo de Viabilidade - Adequação de Instrumentação - Concentração Magnética - Fábrica. Vale/DIFL/GAEEL- Gerência de Engenharia Elétrica e Automação, 2014.

WEIGEND, A. S. *Time series prediction: forecasting the future and understanding the past*. Routledge, 2018.

WERON, R., MISIOREK, A. "Forecasting spot electricity prices: A comparison of parametric and semiparametric time series models", *International journal of forecasting*, v. 24, n. 4, pp. 744–763, 2008.

XIONG, D., HOLMES, R. "Developments in the physical separation of iron ore: magnetic separation". Em: Lu, L. (Ed.), *Iron Ore Mineralogy, Processing and Environmental Sustainability*, Elsevier, cap. 9, pp. 284–307, 2015.

A. Apêndice A: Consulta SQL

```
    SET LOG_ROWS 0;

-- Tabela Final
declare local temporary table module.FINAL(dia int, hora int,
Fe_Alim real, Fe_Con real, Si_Alim real, Si_Con real,
Vazao_Media real, Corrente1 real, Corrente2 real, Agua_Con real,
Agua_Medio real, Dens1 real, Dens2 real);

-- Tabelas temporarias FERRO
declare local temporary table module.TAG1(nome char(30), dia int,
hora int, tempo char(10), valor real); -- FabLabQuiFeALMSIDHor

declare local temporary table module.TAG2(nome char(30), dia int,
hora int, tempo char(10), valor real); -- FabLabQuiFeCOMSE1Hor

--Tabelas temporarias SILICA
declare local temporary table module.TAG11(nome char(30), dia int,
hora int, tempo char(10), valor real);  -- FabLabQuiSiO2ALMSIDHor

declare local temporary table module.TAG12(nome char(30), dia int,
hora int, tempo char(10), valor real);  -- FabLabQuiSiO2COMSE1Hor

--Tabelas temporarias VAZOES
declare local temporary table module.TAG21(nome char(30), dia int,
hora int, tempo char(10), valor real); --  FAB-MSE1-FIT-01

--Tabelas temporarias DENSIDADES
declare local temporary table module.TAG31(nome char(30), dia int,
hora int, tempo char(10), valor real); -- FAB-MSE1-DIT-01

declare local temporary table module.TAG32(nome char(30), dia int,
hora int, tempo char(10), valor real); -- FAB-MSE1-DIT-02

--Tabelas temporarias CORRENTES CAMPO
declare local temporary table module.TAG41(nome char(30), dia int,
hora int, valor real); -- FAB-MSE1-IIT-03
```

```
declare local temporary table module.TAG42(nome char(30), dia int,
hora int, valor real); -- FAB-MSE1-IIT-04

declare local temporary table module.TAG43(nome char(30), dia int,
hora int, tempo char(10), valor real); -- FAB-MSE2-IIT-03

declare local temporary table module.TAG44(nome char(30), dia int,
hora int, tempo char(10), valor real); -- FAB-MSE2-IIT-04

--Tabelas temporarias PRESSAO AGUA CONCENTRADO
declare local temporary table module.TAG51(nome char(30), dia int,
hora int, tempo char(10), valor real); -- FAB-MSE2-PIT-02

--Tabelas temporarias PRESSAO AGUA MEDIO
declare local temporary table module.TAG61(nome char(30), dia int,
hora int, tempo char(10), valor real); -- FAB-MSE2-PIT-01

-- Define quanto tempo de historico se deseja analisar
LOCAL Hora_Inicio_Pesquisa TIMESTAMP;
LOCAL Hora_Fim_Pesquisa TIMESTAMP;
Hora_Inicio_Pesquisa = '01-FEB-19 00:00:00.0';
Hora_Fim_Pesquisa = '01-MAR-19 00:00:00.0';

-- Extracao do teor de ferro na alimentacao
insert into module.TAG1
select name, extract (day from ts) as dia, extract (hour from ts)
as hora, (dia||':'||hora), value from history where name like
'FabLabQuiFeALMSIDHor' and (ts between Hora_Inicio_Pesquisa and
Hora_Fim_Pesquisa) and request = 1 and period = 36000;

-- Extracao do teor de ferro no concentrado
insert into module.TAG2
select name, extract (day from ts) as dia, extract (hour from ts)
as hora,  (dia||':'||hora), value from history where name like
'FabLabQuiFeCOMSE1Hor' and (ts between Hora_Inicio_Pesquisa and
Hora_Fim_Pesquisa) and request = 1 and period = 36000;

-- Extracao do teor de silica na alimentacao
insert into module.TAG11
```

```sql
select name, extract (day from ts) as dia, extract (hour from ts)
as hora, (dia||':'||hora), value from history where name like
'FabLabQuiSiO2ALMSIDHor' and (ts between Hora_Inicio_Pesquisa and
Hora_Fim_Pesquisa) and request = 1 and period = 36000;

-- Extracao do teor de silica na alimentacao
insert into module.TAG12
select name, extract (day from ts) as dia, extract (hour from ts)
as hora, (dia||':'||hora), value from history where name like
'FabLabQuiSiO2COMSE1Hor' and (ts between Hora_Inicio_Pesquisa and
Hora_Fim_Pesquisa) and request = 1 and period = 36000;

-- Extracao da vazao media de alimentacao
insert into module.TAG21
select name, extract (day from ts) as dia, extract (hour from ts) as hora,
(dia||':'||hora), avg(value) as vazao_media from history where name like
'FAB-MSE1-FIT-01'and (ts between Hora_Inicio_Pesquisa and Hora_Fim_Pesquisa)
and request = 5
group by name, dia, hora
order by name, dia, hora;

-- Extracao da densidade media de alimentacao
insert into module.TAG31
select name, extract (day from ts) as dia, extract (hour from ts) as hora,
(dia||':'||hora), avg(value) as vazao_media from history where name like
'FAB-MSE1-DIT-01'and (ts between Hora_Inicio_Pesquisa and Hora_Fim_Pesquisa)
and request = 5
group by name, dia, hora
order by name, dia, hora;

-- Extracao da densidade media de concentrado
insert into module.TAG32
select name, extract (day from ts) as dia, extract (hour from ts) as hora,
(dia||':'||hora), avg(value) as vazao_media from history where name like
'FAB-MSE1-DIT-02'and (ts between Hora_Inicio_Pesquisa and Hora_Fim_Pesquisa)
and request = 5
group by name, dia, hora
order by name, dia, hora;
```

```
-- Extracao da corrente media
insert into module.TAG43
select name, extract (day from ts) as dia, extract (hour from ts) as hora,
(dia||':'||hora), avg(value) as vazao_media from history where name like
'FAB-MSE2-IIT-03'and (ts between Hora_Inicio_Pesquisa and Hora_Fim_Pesquisa)
and request = 5
group by name, dia, hora
order by name, dia, hora;

-- Extracao da corrente media
insert into module.TAG44
select name, extract (day from ts) as dia, extract (hour from ts) as hora,
(dia||':'||hora), avg(value) as vazao_media from history where name like
'FAB-MSE2-IIT-04'and (ts between Hora_Inicio_Pesquisa and Hora_Fim_Pesquisa)
and request = 5
group by name, dia, hora
order by name, dia, hora;

-- Extracao da pressao media de agua de concentrado
insert into module.TAG51
select name, extract (day from ts) as dia, extract (hour from ts) as hora,
(dia||':'||hora), avg(value) as vazao_media from history where name like
'FAB-MSE2-PIT-02'and (ts between Hora_Inicio_Pesquisa and Hora_Fim_Pesquisa)
and request = 5
group by name, dia, hora
order by name, dia, hora;

-- Extracao da pressao media de agua de medio
insert into module.TAG61
select name, extract (day from ts) as dia, extract (hour from ts) as hora,
(dia||':'||hora), avg(value) as vazao_media from history where name like
'FAB-MSE2-PIT-01'and (ts between Hora_Inicio_Pesquisa and Hora_Fim_Pesquisa)
and request = 5
group by name, dia, hora
order by name, dia, hora;

-- Montagem da TABELA FINAL
insert into module.FINAL
select T21.dia, T21.hora, T1.valor, T2.valor, T11.valor, T12.valor,
```

```
T21.valor, T43.valor, T44.valor, T51.valor, T61.valor, T31.valor, T32.valor

from module.TAG1 T1 inner join module.TAG2 T2 using (tempo) inner join
module.TAG11 T11 using (tempo) inner join module.TAG12 T12 using (tempo)
inner join module.TAG21 T21 using (tempo) inner join module.TAG43 T43
using (tempo) inner join module.TAG44 T44 using (tempo) inner join
module.TAG51 T51 using (tempo) inner join module.TAG61 T61 using (tempo)
inner join module.TAG31 T31 using (tempo) inner join
module.TAG32 T32 using (tempo);

--Consulta na TABELA FINAL ordenada por dia e hora
select * from module.FINAL
order by dia, hora;
```

B. Apêndice B: Código Matlab

```
clc;
% clear all;
clearvars -except UTheil MAPE
close all hidden;

n = 2; % ordem do autoregressivo
Lambda = 1; %taxa de esquecimento

%Leitura dos dados - Inserir apenas uma serie de Dados

%Dados Amostrados de Setembro
Saida = xlsread('Setembro Amostrado.xlsx','C:C');

Output = Saida;

N = size(Output,1);

Output0 = Output(1:N/30);

N0 = size(Output0,1);


%%%%%ESTIMACAO INICIAIS DOS PARAMETROS
%Sao considerados os primeiros N0 valores de y para estimar os parametros
%iniciais

%Considerando y = PSI * theta
%Para os parametros iniciais: y = PSI0 * theta0
%Logo: theta0 = PSI0^(-1) * y
%Porem, como PSI nao e quadrado:
% theta0 = %[transp(PSI)*PSI]^(-1)*transp(PSI) * y


Output1 = Output0(n+1: N0);
Output2 = Output0(n: N0-1);

%MATRIZ PSI0
PSI0 = Output2;
for i=2:n
    PSI0 = horzcat(PSI0,Output0(n-i+1: N0-i));
end


```

```
P_k = inv(PSI0'*PSI0);

%Obtencao dos parametros iniciais
theta0 = P_k*PSI0'*Output1;

%Obtencao dos valores do parametro A
A = [1 -theta0(1)];
for i=2:n
    A = horzcat(A, -theta0(n));
end

%Criando sistema para simulacao
sys = idpoly(A,[],[],[],[],0,1);

%Simulando para os primeiros N0 valores
for i=n+1:N0
    yf(i,1) = forecast(sys,Output(1:i),1);
    ynaive(i,1) = Output(i-1);
    e(i) = Output(i) - yf(i);
    en(i) = Output(i) - ynaive(i);
    if (Output(i) - Output(i-1))*(yf(i) - yf(i-1)) > 0
        indicador(i,1) = 1;
    end
    if (Output(i) - Output(i-1))*(yf(i) - Output(i-1)) > 0
        indicador2(i,1) = 1;
    end
end

%ESTIMACAO RECURSIVA DOS PARAMETROS
%Primeiros valores sao os parametros obtidos via metodo NAO RECURSIVO
theta(:,1) = theta0;

for i=N0+1:N

    %Montando o vetor de valores regressivos
    phi = [Output(i - 1)];
    for j = 2:n
        phi = horzcat(phi, Output(i - j));
    end

    phi = phi';

    %Definindo a Matriz de ganhos, sendo o primeiro P_K obtido via metodo
    %NAO RECURSIVO
    K_k = (P_k*phi)/(phi'*P_k*phi + Lambda);

    %Estimando os parametros baseado em y, phi, K_k e nos parametros
```

```
    %anteriores
    theta(:,i-N0+1) = theta(:,i-N0) + K_k*(Output(i) - ...
        phi'*theta(:,i-N0));

    %Atualizacao de P_K
    P_k_ant = P_k;
    P_k = 1/Lambda * (P_k_ant - ...
        (P_k_ant*phi*phi'*P_k_ant)/(phi'*P_k_ant*phi+Lambda));

    %Obtencao dos valores do parametro A do passo i
    A = [1 -theta(1,i-N0+1)];
    for j = 2:n
        A = horzcat(A, -theta(j,i-N0+1));
    end

    sys = idpoly(A,[],[],[],[],0,1);
%     data = iddata(Output(1:i), Input(1:i));
    yf(i,1) = forecast(sys,Output(1:i),1);
    ynaive(i,1) = Output(i-1);
    e(i) = Output(i) - yf(i-1);
    en(i) = Output(i) - ynaive(i);
    m1(i) = (e(i)/Output(i))*100;
    m2(i) = (en(i)/Output(i))*100;

    if (Output(i) - Output(i-1))*(yf(i) - yf(i-1)) > 0
        indicador(i) = 1;
    end
    if (Output(i) - Output(i-1))*(yf(i) - Output(i-1)) > 0
        indicador2(i,1) = 1;
    end
end

Tend = sum(indicador)/N;
Tend2 = sum(indicador2)/N

plot(Output,'b'); hold; plot(yf,'r'); plot(ynaive,'g'); legend('Dados ...
    Reais','Previsao AR(2)','Previsao Naive','Location','southeast');
xlabel('N Amostra');
%ylabel('%SiO2'); set(gca,'YLim',[10 80]);
ylabel('%Fe'); set(gca,'YLim',[30 80]);

% Definindo area de ZOOM
h = gcf; a = gca;
% Create correct position vector
szi = [50 100 33 46];
% Get the inset location
szin = [120 340 55 78];
```

```
MagInset(h,a,szi,szin,{'NW','NW';'SE','SE'});
aux = gca;
set(aux.Children, 'linewidth',2)
f1 = gcf; saveas(f1,strcat('Amost_Fe_SET_VGR(',string(n),') - ...
    L',string(Lambda),'_Previsao.fig'))

figure;
plot(e,'r'); hold; plot(en,'g'); legend('Erro AR(2)', 'Erro ...
    Naive','Location','southeast');
xlabel('N Amostra'); ylabel('%');
set(gca,'YLim',[-10 45]);

% Definindo area de ZOOM
h = gcf; a = gca;
% Create correct position vector
szi = [50 100 -8 12];
% Get the inset location
szin = [120 340 15 48];
% Do the thing
MagInset(h,a,szi,szin,{'NW','NW';'SE','SE'});
aux = gca;
set(aux.Children, 'linewidth',2)
f2 = gcf; saveas(f2,strcat('Amost_Fe_SET_VGR(',string(n),') - ...
    L',string(Lambda),'_Erros.fig'))

figure;
plot(theta(1,:),"LineWidth",2.0);

if n==2
    hold; plot(theta(2,:),"LineWidth",2.0); legend('Parametro A1', ...
        'Parametro A2');
elseif n==3
    hold; plot(theta(2,:),"LineWidth",2.0); ...
        plot(theta(3,:),"LineWidth",2.0); legend('Parametro A1', ...
        'Parametro A2', 'Parametro A3');
else
    legend('Parametro A1');
end

xlabel('N Amostra');
%set(gca,'XLim',[1500 1700]);
f3 = gcf; saveas(f3,strcat('Amost_Fe_SET_VGR(',string(n),') - ...
    L',string(Lambda),'_Param.fig'))

U = (sqrt((Output - yf)'*(Output - yf)))/(sqrt((Output - ...
    ynaive)'*(Output - ynaive)))
MAPE1 = mean(abs(m1))
```

```
MAPE2 = mean(abs(m2));
RMSE = sqrt((e*e')/N)
RMSEN = sqrt((en*en')/N);
```