



UNIVERSIDADE FEDERAL DE CAMPINA GRANDE – UFCG
CENTRO DE CIÊNCIAS E TECNOLOGIA – CCT
UNIDADE ACADÊMICA DE ENGENHARIA QUÍMICA - UAEQ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA - PPGEQ

DISSERTAÇÃO DE MESTRADO

**DESACOPLAMENTO DE SISTEMAS DE CONTROLE
MULTIVARIÁVEIS POR ICA COM MODIFICAÇÃO DO
BRANQUEAMENTO**

Fábio George Nogueira Cruz

Orientador: Prof. Dr. José Nilton Silva

CAMPINA GRANDE

2017

FÁBIO GEORGE NOGUEIRA CRUZ

**DESACOPLAMENTO DE SISTEMAS DE CONTROLE MULTIVARIÁVEIS POR
ICA COM MODIFICAÇÃO DO BRANQUEAMENTO**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Química da Universidade Federal de Campina Grande, como parte dos requisitos necessários para obtenção do título de Mestre em Engenharia Química.

Orientador: Prof. Dr. José Nilton Silva

Área de concentração: Modelagem e Simulação

**Campina Grande – PB
2017**

FICHA CATALOGRÁFICA ELABORADA PELA BIBLIOTECA CENTRAL DA UFCG

C957d Cruz, Fábio George Nogueira.
Desacoplamento de sistemas de controle multivariáveis por ICA com modificação do branqueamento / Fábio George Nogueira Cruz.– Campina Grande, 2017.
66 f. il. color.

Dissertação (Mestrado em Engenharia Química) – Universidade Federal de Campina Grande, Centro de Ciências e Tecnologia, 2017.
"Orientação: Prof. Dr. José Nilton Silva".
Referências.

1. Tratamento de Sinais – Engenharia Química. 2. Independent *Component Analysis* - ICA. 3. Sistemas de Controle de Processos – Uso de Sensores. 4. Monitoramento de Plantas Industriais. I. Silva, José Nilton. II. Título.

CDU 66.012(043)

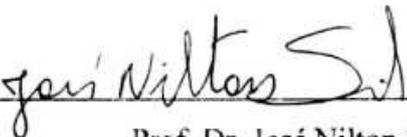


UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
 PRÓ-REITORIA DE PÓS-GRADUAÇÃO E PESQUISA
 CENTRO DE CIÊNCIAS E TECNOLOGIA
 PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA

DESACOPLAMENTO DE SISTEMAS DE CONTROLE MULTIVARIÁVEIS POR
 ICA COM MODIFICAÇÃO DO BRANQUEAMENTO.

BANCA EXAMINADORA

PARECER



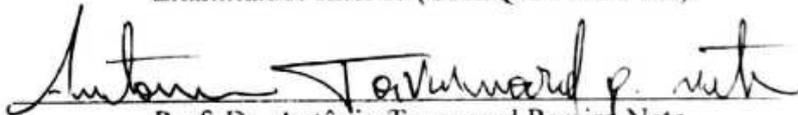
APROVADO

Prof. Dr. José Nilton Silva
 Orientador (UAEQ/CTT/UFCG)



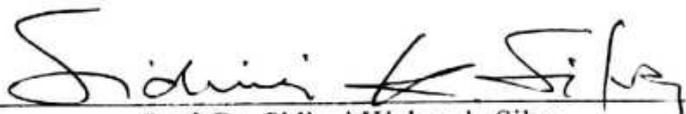
APROVADO

Prof. Dr. Luis Gonzaga Sales Vasconcelos
 Examinador Interno (UAEQ/CTT/UFCG)



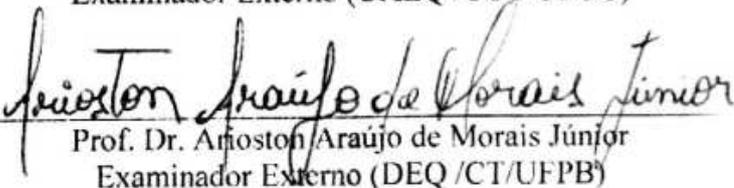
APROVADO

Prof. Dr. Antônio Tavernard Pereira Neto
 Examinador Interno (UAEQ/CCT/UFCG)



Aprovado

Prof. Dr. Sidinei Kleber da Silva
 Examinador Externo (UAEQ /CCT/UFCG)



Aprovado

Prof. Dr. Afonso Araújo de Moraes Júnior
 Examinador Externo (DEQ /CT/UFPB)

*Dedica essa Dissertação a Minha mãe, Francisca Jorge Cruz e a Minha Tia, Maria Luiza
Cruz Oliveira*

AGRADECIMENTO

A Deus por ter me dado força, apoio e proteção durante as situações difíceis, pelas inúmeras bênçãos concedidas e por ser meu Guia, estando sempre ao meu lado durante esta caminhada.

A Minha mãe Francisca Jorge cruz por ter me protegido e me ensinado a ser o que sou.

A Minha tia Maria Luiza Cruz Oliveira por me apoiar e me aconselhar sempre que eu preciso. A minha irmã Ana Luisa Nogueira Cruz, por fazer parte da minha vida e me incentivar a ser uma pessoa melhor a cada dia. A todos da FAMÍLIA CRUZ por me apoiarem e proporcionarem momentos felizes quando reunidos.

Aos meus velhos amigos, que desde dos tempos de colégio, me fizeram rir nas horas mais improváveis e estiveram do meu lado sempre que precisei

Aos novos amigos, feitos durante o período de estudos na UFCG. Que, junto comigo, passaram por muitas dificuldades durante esse período, mas que sempre me apoiaram, trazendo momentos de alegria. A todos os amigos, velhos e novos, que demonstraram serem irmãos na amizade.

Aos “Grandes” Ezequiel, Ângela e demais colegas da pós-graduação, por serem amigos de verdade.

Ao Dr. José Nilton Silva, pelo o conhecimento transmitido, pela amizade, confiança transmitida durante o período de realização do trabalho.

Aos professores da Unidade Acadêmica de Engenharia Química pelo conhecimento transmitido ao longo do período do mestrado.

A todos que contribuíram diretamente ou indiretamente para a elaboração deste trabalho.

“Transformar o simples em complicado é fácil, porém transformar o complicado em simples exige criatividade”

Edward Elric

LISTA DE FIGURAS

Figura 1– Problema <i>Cocktail Party</i>	12
Figura 2 - Sinais fontes de Referência.	19
Figura 3 - Sinais estimados pelo o ICA por PCA.	19
Figura 4 - Exemplo de interação entre as variáveis do processo multivariável.	24
Figura 5 - Estrutura de um desacoplador para o sistema TITO.	29
Figura 6 – Estrutura do desacoplador invertido.	30
Figura 7– Diagrama das etapas de aplicação do MOD-ICA.	33
Figura 8 – Diagrama das etapas de aplicação do MOD-ICA.	34
Figura 9 – Esquema de desacoplamento proposto.	36
Figura 10- Sinais originais: (a) – Seno Duplo; (b) – Onda duplo; (c) – Onda Periódica;	37
Figura 11- Sinais Misturados pela a matriz A.	38
Figura 12- Sinais estimados pelo o FastICA: (a) – Seno duplo; (b) – onda dupla; (c) – Onda periódica. Sendo o sinal em vermelho e azul o estimado e de referência respectivamente.	38
Figura 13 - Sinais estimados pelo o JADE: (a) – Seno duplo; (b) – onda dupla; (c) – Onda periódica. Sendo o sinal em vermelho e azul o estimado e de referência respectivamente.	39
Figura 14 - Sinais estimados pelo ICA por PCA: (a) – Seno duplo; (b) – onda dupla; (c) – Onda periódica. Sendo o sinal em vermelho e azul o estimado e de referência respectivamente.	40
Figura 15 - Sinais estimados pelo ICA por PCA com correção: (a) – Seno duplo; (b) – onda dupla; (c) – Onda periódica. Sendo o sinal em vermelho e azul o estimado e de referência respectivamente.	41
Figura 16 - Desvio de estimação para o seno duplo: Comparativo entre as quatro estimativas.	41
Figura 17 - Desvio de estimação para a Onda duplo: Comparativo entre as quatro estimativas.	42
Figura 18 - Desvio de estimação para a Onda Periódica: Comparativo entre as quatro estimativas.	42
Figura 19 - Implementação da matriz de separação.	47
Figura 20 - Fluxograma de produção de etanol anidro simulada em Aspen Dynamics.	49
Figura 21– Variação da Temperatura do estágio 22 da “C102” com o tempo.	50
Figura 22 – Variação da Temperatura do estágio 8 da “C102” com o tempo.	51
Figura 23 - Variação da Temperatura do estágio 7 da “C102” com o tempo.	51
Figura 24 - Variação da Temperatura do estágio 22 da “C101” com o tempo.	52
Figura 25– Variação da Temperatura do estágio 21 da “C101” com o tempo.	52
Figura 26 - Variação da Composição de etanol na corrente de destilado da “C101” com o tempo.	53
Figura 27 – Variação da Composição de água na corrente de destilado da “C102” com o tempo.	54
Figura 28 – Variação da Composição de solvente na corrente de base da “C102” com o tempo.	54
Figura 29 – Variação da Temperatura do estágio 8 da “C102” com o tempo.	55
Figura 30 - Variação da Temperatura do estágio 7 da “C102” com o tempo.	55
Figura 31 - Variação da Temperatura do estágio 22 da “C101” com o tempo.	56
Figura 32 - Variação da Temperatura do estágio 21 da “C101” com o tempo.	56
Figura 33– Variação da Composição de etanol no destilado da “C101” com o tempo.	57
Figura 34 - Variação da Composição de água no destilado da “C102” com o tempo.	57
Figura 35 - Variação da Composição de solvente na corrente de base da “C102” com o tempo.	57

LISTA DE TABELA

Tabela 1 - Índice de desempenho	43
Tabela 2 - Emparelhamento proposto pelo SVD Clássica e SVD com a metodologia MOD-ICA	44
Tabela 3 - RGA para a SVD Clássica	44
Tabela 4- RGA para a SVD/MOD - ICA	45
Tabela 5- RGA para os sistemas 4x4 a partir do SVD Clássica e SVD MOD-ICA	45
Tabela 6- Especificações de controle	48

LISTA DE SIGLAS

AG	Algoritmos Genéticos
BSS	<i>Blind Source Separation</i>
CCT	<i>Channel Components Transform</i>
EEMD	<i>Ensemble Empirical Model Decomposition</i>
EVD	<i>Eigenvalues Decomposition</i>
FastICA	<i>Fast Independent Component Analysis</i>
fMRI	<i>Functional Magnetic Resonance Imaging</i>
IAE	<i>Integral of the Absolute Magnitude of the Error.</i>
ICA	<i>Independent Component Analysis</i>
ISE	<i>Integral Square Error</i>
ITAE	<i>Integral of the Time-Weighted Absolute Error</i>
JADE	<i>Joint Approximate Diagonalization of Eigenmatrices</i>
KICA	<i>Kernel Independent Component Analysis</i>
KTSICA	<i>Kernel Time Structure Independent Component Analysis</i>
MIMO	<i>Multiple Input Multiple Output</i>
MOD-ICA	<i>Modified - Independent Component Analysis</i>
MPC	<i>Model Predictive Control</i>
MSPM	<i>Multivariate Statistical Process Monitoring</i>
MTEB	<i>Methyl Tert-butyl Ether</i>
NIR	<i>Near Infrared</i>
PCA	<i>Principal Component Analysis</i>
PSO	<i>Particle Swarm Optimization</i>
RGA	<i>Relative Gain Array</i>
SISO	<i>Single Input Single Output</i>
SVD	<i>Singular Value Decomposition</i>
TITO	<i>Two Input Two Output</i>
VIMFs	<i>Virtual Intrisec Model Functions</i>

LISTA DE SÍMBOLOS

X	<i>Matriz de Sinais Misturados</i>
S	<i>Matriz de Componentes Independentes</i>
a_{ij}	<i>Coefficientes Reais da Matriz de Mistura</i>
A	<i>Matriz de Mistura</i>
N	<i>Número de Sinais</i>
S_n	<i>Vetor Sinal de Referência</i>
X_n	<i>Vetor de Sinais Misturados</i>
W	<i>Matriz de Separação</i>
w_i	<i>Vetores Linhas da Matriz de Separação</i>
W^*	<i>Matriz de Separação Estimada</i>
Y	<i>Matriz dos Sinais Estimados pelo a ICA</i>
P	<i>Matriz de Permutação</i>
$Kurt(s)$	<i>Kurtosis para o Sinal Aleatório s</i>
$E\{s\}$	<i>Operador Esperança para o Sinal Aleatório s</i>
Y	<i>Variável Aleatória</i>
Y_{gauss}	<i>Variável Aleatória de Gauss</i>
$H(Y)$	<i>Entropia Diferencial</i>
$f_Y(.)$	<i>Função de Densidade para a Variável Aleatória y</i>
$J(.)$	<i>Negentropia</i>
k_i	<i>Termo Constante</i>
v	<i>Variável Gaussiana</i>
G_i	<i>Funções não-quadráticas</i>
$Cov(Y_i, Y_j)$	<i>Calculo da Covariância entre duas Variáveis</i>
v	<i>Vetor Aleatório</i>
Z	<i>Matriz de Dados Branqueados</i>
U	<i>Matriz Ortogonal</i>
β	<i>Termo Constante</i>
G'	<i>Derivada das Função não-Quadráticas.</i>
w_i^t	<i>Transpostas dos Vetores Linhas da Matriz de Separação</i>
x_g	<i>Variável Gaussiana</i>
Q	<i>Matriz de Branqueamento para o Algoritmo JADE</i>

$z(k)$	<i>Vetor de Dados Branqueados para o Algoritmo JADE</i>
U^T	<i>Matriz de Separação para o Algoritmo JADE</i>
M	<i>Valor Médio</i>
X_c	<i>Vetor de Mistura Centralizado</i>
I	<i>Matriz Identidade</i>
Z_i	<i>Vetor Linha de Sinais Branqueados</i>
V	<i>Matriz de Branqueamento para o ICA por PCA</i>
E	<i>Matriz Ortogonal de Autovetores</i>
D	<i>Matriz Diagonal dos Autovalores</i>
\hat{A}	<i>Matriz de Mistura com Parâmetros Reduzidos</i>
G_{ij}	<i>Funções de Transferência para o Processo MIMO</i>
$u_i(k)$	<i>Variáveis Manipuladas</i>
$y_i(k)$	<i>Variável de Processo</i>
K_{ij}	<i>Ganhos para o Regime Permanente</i>
I_{ij}	<i>Ganho Relativo Adimensional</i>
U	<i>Matriz Ortogonal para a SVD</i>
V	<i>Matriz Ortogonal para a SVD</i>
u_i	<i>Termos da Matriz U da SVD</i>
v_i	<i>Termos da Matriz V da SVD</i>
g_c	<i>Número Condicionante</i>
$D(s)$	<i>Matriz de Desacoplamento</i>
$C(s)$	<i>Matriz de Elementos de Controle</i>
$Q(s)$	<i>Matriz de Transferência Diagonalizada</i>
ΔMV_i	<i>Varição Degrau nas Variáveis Manipuladas</i>
ΔPV_i	<i>Ganhos das Variáveis de Saída</i>
ΔPV^*_i	<i>Matriz de Ganhos para o MOD-ICA</i>

Sumário

1.	INTRODUÇÃO	1
2.	OBJETIVOS	4
2.1.	Geral	4
2.2.	Específicos	4
3.	REVISÃO BIBLIOGRÁFICA	5
3.1.	Estado da Arte	8
4.	FUNDAMENTAÇÃO TEÓRICA	11
4.1.	Análise de Componentes Independentes	11
4.2.	Ambiguidade da análise do ICA	13
4.3.	Restrições do Modelo ICA	14
4.3.1.	Não – Gaussianidade	14
4.3.1.1.	Não-gaussianidade por Kurtosis	14
4.3.1.2.	Não-gaussianidade por Entropia/Negentropia	15
4.3.2.	Independência Estatística	16
4.3.3.	Matriz de Mistura Quadrada	17
4.4.	Algoritmo ICA utilizando PCA	17
4.4.1.	Problemas envolvendo a estimação pela ICA por PCA	18
4.5.	Algoritmo <i>FastICA</i>	20
4.6.	Algoritmo <i>JADE</i>	21
4.7.	Pré – Processamento do Sinal	21
4.7.1.	Centralização	22
4.7.2.	Branqueamento	22
4.8.	Processos Multivariados	24
4.8.1.	Análise dos Sistemas Multivariáveis	25
4.8.1.1.	Controlabilidade	25
4.8.1.2.	Grau de interação nas variáveis do processo	25
4.8.1.3.	Decomposição por valor singular (SVD)	26
4.8.1.4.	Número Condicionante	27
4.9.	Desacoplamento de processos multivariados	27
4.9.1.	Desacoplador ideal	29
4.9.2.	Desacoplador Simplificado	29
4.9.3.	Desacoplador invertido	30
5.	METODOLOGIA	32

5.1.	Sistema com mistura artificial.....	32
5.2.	Aplicação da Técnica de desacoplamento	33
5.2.1.	Processo de obtenção do etanol anidro	34
6.	RESULTADOS	37
6.1.	Aplicação das técnicas clássicas.....	37
6.2.	Aplicação da modificação proposta.....	40
6.3.	Emparelhamento pela a técnica SVD utilizando a metodologia MOD-ICA	43
6.4.	Cálculo da Matriz de ganhos relativos	44
6.5.	Avaliação dinâmica dos pares de controle propostos	46
6.5.1.	Simulação dinâmica do sistema proposto.....	50
7.	CONCLUSÕES	58
8.	REFERÊNCIAS	60

RESUMO

A utilização de sensores em sistemas de controle de processos é de vital importância para o monitoramento e operação adequada das plantas industriais. Por sua vez, os sinais podem apresentar interferências de outras fontes, além de que em certos casos, não é possível observar diretamente os sinais individuais das fontes. Diante disso, as técnicas de processamento e separação de sinais são utilizadas no intuito de extrair as informações das fontes contidas nos sinais misturados. As principais técnicas de separação de sinais estão associadas a técnica ICA (*Independent Component Analysis*), que sofreu significativa evolução desde sua criação nos anos 80. Tal evolução teve contribuição também da técnica PCA (*Principal Component Analysis*) e do desenvolvimento da capacidade de processamento computacional. No entanto, essas técnicas apresentam dois problemas básicos, a saber: desvio de amplitude e mudança de fase, sendo tais problemas limitantes quanto a sua utilização em sistemas de controle. Sendo assim, esse trabalho tem como objetivo apresentar uma solução do problema de amplitude das técnicas ICA's para utilização na redução do acoplamento de sistemas multivariáveis. A correção proposta, baseada na correção da etapa de branqueamento dos algoritmos ICA, gerando a técnica MOD-ICA, foi utilizada como alternativa para a quebra da correlação entre variáveis dos sistemas multivariados. Essa técnica foi utilizada para o projeto e obtenção dos pares de controle de uma planta de produção de etanol anidro modelada na plataforma *Aspen Dynamics*. No estudo de caso proposto, foi observada uma redução significativa no número condicional dos pares de controle propostos, e a matriz de separação foi utilizada como parâmetro de desacoplamento do sistema de controle. Dessa forma, a técnica proposta MOD-ICA apresentada pode ser utilizada como ferramenta de geração de projeto de sistemas de controle, podendo a matriz de separação ser considerada como modelo de redução de acoplamento, resultando assim na obtenção de um sistema de controle mais robusto às variações inerentes do processo.

Palavras-Chave: Tratamento de sinais, ICA, Desacoplamento, Controle de processos

ABSTRACT

The use of sensors in process control systems is of vital importance for the proper operation and monitoring of industrial plants. In turn, process signals may have interference from other sources and, in some cases, it is not possible to observe directly the individual signals of the sources. In view of this, signal processing and separation techniques are used in order to extract the information from the sources contained in mixed signals. The main signal separation techniques are associated with the Independent Component Analysis (ICA), which has undergone significant evolution since its creation in the 1980s. Such evolution also had the contribution of the Principal Component Analysis (PCA) and the development of computational processing power. However, these techniques have two basic glitches: deviation of amplitude and phase change, which limit their use in control systems. Therefore, this research aims to present a solution to the problem of amplitude in ICA techniques for use in decoupling reduction in multivariate systems. The proposed correction, based on the stage of whitening ICA algorithms, which generated the technique MOD-ICA, was used as an alternative to breaking the correlation between variables in multivariate systems. Such technique was used for projecting and obtaining controlling pairs in an industrial plant of anhydrous ethanol production modeled on the Aspen Dynamics platform. In the case study proposed in this research, a significant reduction in the conditional numbers of the proposed controlling pairs was observed, and the separating matrix was used as a parameter of decoupling for the control system. As a result, the proposed MOD-ICA technique can be used as a tool for generating control systems, and its separating matrix can be considered as a model for decoupling reduction, which results in a more robust control system for process variation.

Keywords: Signal processing, ICA, decoupling, Process control

1. INTRODUÇÃO

Em muitas situações de medição de sinais, como por exemplo em indústrias, é necessário o uso de sensores para coletar informações, nas quais geralmente contém problemas nos sinais fornecidos, resultando em misturas dos sinais desejados. Além disso, em geral, não há como observar as fontes diretamente, nem é conhecida a forma como as fontes foram misturadas (MORETO, 2008).

É nesse contexto que surge o problema da Separação Cega de Fontes (*BSS- Blind Source Separation*), que tem como função estimar os sinais originais, possuindo somente a informação das suas misturas. Como dito, o termo “Cega” refere-se ao fato de que não se tem nenhuma informação a respeito dos sinais originais e de que forma os mesmos foram misturados.

Em relação a Separação Cega de Fontes, um problema típico investigado é o problema “*cocktail party*” ou separação de sinais de áudio. Considere duas pessoas conversando em uma sala fechada, com sensores, os quais realizam a captura das vozes presentes. O problema está relacionado em isolar os sinais captados pelos os sensores, sabendo que os mesmos estão correlacionados. A particularidade da separação Cega de fontes perante as outras técnicas de filtragens é que, nesse caso, não é necessário conhecer precisamente os sinais das fontes (HYVÄRINEN, 1999a). Um dos métodos mais difundidos para BSS, principalmente para o problema de *Cocktail Party*, é a Análise de Componentes Independentes (ICA).

Apesar dos primeiros estudos sobre processamento de sinais ter início com os estudos de Bode e Shannon no final da década de 1940 e no início da década de 1950. (BOLDE e SHANNON, 1950) com o estudo de filtragem temporal (HALKIN, 2001b), atualmente tornou-se um tema importante em pesquisas contemporâneas, visto que possui grande aplicabilidade dentro da engenharia. O surgimento de novas técnicas de separação vem sendo incentivada pela a necessidade de superar os limites teóricos das técnicas clássicas, possibilitando resoluções de problemas, tais como, separação de imagens, aplicação em sensores e em sistemas multivariáveis, como o processamento de sinais MIMO (*Multiple Input – Multiple Output*) (BIRBAUMER *et al.*, 2007).

Grande parte dos sistemas multivariáveis apresentam interações entre suas entradas e saídas. Controlar esses tipos de sistemas tem suas limitações devido ao acoplamento do sistema. No contexto de controle de processos, os métodos de controle consolidados, para sistemas SISO (*Single Input – Single Output*), nem sempre são eficientes no controle de sistemas MIMO

(*Multiple Input – Multiple Output*) (CHEN, ZHANG, 2006). A consideração de interações em sistemas de controle é importante, devido ao fato, de que boa parte dos sistemas industriais modernos, envolvem uma quantidade considerável de variáveis com um certo grau de inter-relação (SOUSA *et al.*, 2014). Nesses problemas de processamento de sinais MIMO, é desejável encontrar uma transformação dos dados de modo a tornar sua estrutura com um menor grau de interação.

Uma das alternativas para a diminuição das interações entre as variáveis, nos sistemas MIMO, é a utilização de métodos de desacoplamento. A essência de um método de desacoplamento é introduzir dinâmicas que cancelem as interações existentes entre as variáveis do processo, permitindo que seja feito um controle independente para cada uma das malhas do sistema (GARRIDO *et al.*, 2011). Dentre várias técnicas, utilizadas nesse tipo de processo pode-se citar: Aprendizado não Supervisionado; Análise de Componentes Principais (PCA); Análise de Fatores; Análise de Componentes Independentes (ICA); Separação Cega de Fontes (BBS); Decomposição em Valor Singular (*SVD – Singular Value Decomposition*).

A técnica SVD proposta por Moore, (1986) tem como princípio básico utilizar os ganhos em malha aberta, para determinar quais variáveis são mais sensíveis à mudanças nas variáveis manipuladas dos processos, bem como quais dessas variáveis manipuladas apresentam maior impacto, determinando também o grau de dificuldade de satisfazer os objetivos de controle, em função da quantidade de pares utilizados.

A análise de componente independentes (ICA) é um algoritmo popular de processamento de sinais e separação cega, tendo dentro dos algoritmos ICA aqueles que utilizam AG (algoritmos Genéticos) empregando a Negentropia (KAI; MINGLI, 2006). Destacando também os estudos preliminares realizado por Yoshioka *et al.* (1998), que emprega a divergência de Kullback Leibler (1951).

A técnica de processamento de sinais por (ICA) é um método estocástico e computacional, cuja finalidade é buscar uma representação linear dos dados não-gaussianos, de modo que esses componentes sejam estatisticamente independentes ou tenham sua dependência estatística minimizada. É muitas vezes conhecida como uma técnica de separação cega de fontes, que consiste em extrair ou separar um conjunto de sinais misturados. É aplicado em áreas como o processamento de sinais, eletromagnetismos, sensores químicos, redes de telecomunicações, satélites (LEITE, 2013).

Trabalhos anteriores, tal como o de Kun e Chan (2006) tentam melhorar a qualidade da separação pela análise de componentes independentes por incorporação de estatísticas de ordem superior sob a forma de momentos de segunda ordem e pela Análise de Componentes Principais. Entretanto, a modificação ainda apresenta problemas quanto a amplitude e a fase do sinal estimado, com relação ao sinal de referência. O que também é observado quando se utiliza outros tipos de algoritmos de ICA.

Portanto, esse trabalho tem como objetivos inserir um ajuste de correção de amplitude na metodologia ICA, baseado no estudo do processo de branqueamento dos sinais, possibilitando uma melhor convergência na estimação dos sinais de referência. Após os ajustes na metodologia ICA é proposto nesse trabalho, a sua aplicação, em conjunto com a técnica SVD como forma de se obter os emparelhamentos das variáveis de controle de forma mais desacoplada possível.

2. OBJETIVOS

2.1. Geral

Propor uma correção para o problema de amplitude da técnica ICA e utilização como ferramenta para obtenção de desacopladores de sistemas multivariáveis.

2.2. Específicos

- Avaliar as técnicas de separação por ICA e de emparelhamento por SVD;
- Apresentar as etapas essenciais para a utilização do algoritmo de ICA por PCA;
- Propor modificação na etapa de branqueamento para a metodologia ICA;
- Comparar a técnica ICA modificada com as clássicas;
- Realizar estudos de casos a partir de sinais gerados por fontes misturadas;
- Quantificar a contribuição da modificação do método ICA quanto a redução do desvio de amplitude dos sinais estimados;
- Determinar um novo emparelhamento, baseado na utilização da técnica ICA em conjunto com a metodologia SVD;
- Comparar o emparelhamento obtido com a modificação em relação a SVD clássica;
- Realizar teste das malhas obtidas aplicando distúrbio na planta de processo e avaliar o comportamento dos sistemas de controle;

3. REVISÃO BIBLIOGRÁFICA

A Análise de Componentes Independentes (ICA) teve os seus primeiros trabalhos formulados por Herault, Jutten e Ans (1985) e Herault e Jutten (1986). Os trabalhos desses autores foram motivados pelo estudo na área de processamento de sinais neurofisiológicos relacionados à codificação empregada pelo sistema nervoso central para ativação muscular. O modelo proposto pelos mesmos diz respeito a uma técnica para obter informações separadas de posição e velocidade angular a partir da observação de sinais sensoriais de contração muscular.

A técnica foi denominada Análise de Componentes Independentes (ICA) devido as suas similaridades com a análise de componentes principais (PCA – *Principal Component Analysis*), considerando que a diferença fundamental entre as duas técnicas é que a PCA obtém componentes não correlacionados, enquanto que a ICA deseja encontrar os componentes estatisticamente independentes. A partir dessa junção entre o método ICA e PCA para separação de sinais, foi possibilitado a abertura para várias outras pesquisas.

Em 1989, com a realização do primeiro workshop internacional, foram divulgados estudos na área de análise espectral com a utilização de momento de ordens superiores com trabalhos em ICA de Cardoso (1989) e Comon (1994). Em seu trabalho, Cardoso (1989) usou métodos algébricos como tensores cumulantes de quarta ordem que conduziram à criação do algoritmo JADE (*Joint Approximate Diagonalization of Eigenmatrices*) (CARDOSO e SOULOUMAIAC, 1993). Já o trabalho de Comon (1994) se delineou uma estrutura matemática mais compatível e melhor definida para a ICA, demonstrando como a independência estatística está inserida no problema de separação das fontes. Esse trabalho foi de total importância para o desenvolvimento de novos métodos de BSS (*Blind Source Separation*).

Com o desenvolvimento do BSS/ICA, pode-se destacar os trabalhos do grupo composto pelos pesquisadores finlandeses: Karhunen, Oja e Hyvärinen (2001). Visto que eles interpretaram a ICA como uma extensão linear da Técnica PCA. Tal abordagem teve um papel fundamental para o entendimento da ICA como ferramenta relevante em análise de dados multivariados. Destaca-se, nessa pesquisa, a contribuição de Hyvärinen com o critério da maximização da não-gaussianidade e do algoritmo FastICA (*Fast Independent Component Analysis*) (HYVÄRINEN e OJA, 2000).

Com o crescente desenvolvimento da Técnica ICA, a sua “aplicabilidade” foi se diversificando em inúmeras áreas e aos poucos se “afastando” da BSS. Além das contribuições expostas anteriormente, há outro trabalho importante desenvolvido por Kun Zhang e Lai-wan Chan (2006), da Universidade de Hong Kong, em que foi proposto uma nova abordagem de ICA utilizando PCA (KUN e CHAN, 2006).

Portanto, pode-se constatar que algoritmos com base em ICA vêm fornecendo excelentes soluções, sendo aplicados em diversos campos de pesquisas e de desenvolvimento tecnológicos.

A teoria de controle de múltiplas malhas (descentralizado), vem sendo empregada com grande sucesso na indústria, embora não apresente, em alguns casos um bom desempenho no controle de sistemas, que possuem características complexas. A utilização do termo “descentralizado” é devido a utilização de vários algoritmos de controle independentes, ou seja, referindo-se a utilização de apenas uma variável de saída do processo para determinação do valor de apenas uma variável manipulada.

O projeto de sistemas de controle, aplicado de forma descentralizado foi umas das primeiras abordagens empregada para os processos industriais multivariados (MARLIN, 1995). Esse tipo de abordagem apresenta vantagens como: proporcionar estruturas simples dos algoritmos de controle, reduzindo o esforço computacional; facilidade para modificações das estruturas implementadas e utilização de controle desacoplados nas aplicações em processos industriais. Entretanto, de acordo com Luyben (1990), esse tipo de abordagem apresenta limitações, como por exemplo: fortes níveis de interação e sistemas instáveis em malha aberta.

As pesquisas relacionadas ao controle multivariado descentralizado presentes na literatura são divididas em cinco grandes categorias, realizadas de forma paralela ao desenvolvimento dos projetos de controle, a saber: seleção do conjunto de variáveis para o problema de controle; métodos para a escolha dos pares de variáveis; análise das interações dos pares selecionados; estrutura do sistema de desacoplamento; e avaliação dinâmica do sistema em malha fechada.

Seguindo as categorias apresentadas para o projeto de sistemas descentralizados, tem-se a ferramenta de decomposição em valor singular (SVD – *Singular Value Decomposition*) foi proposta por Moore em 1986, como um método para a definição dos melhores emparelhamentos entre os pares de controle. Sendo aplicado desde a fase de concepção do processo industrial, até na aplicação em plantas já em operação e definindo as melhores posições dos sensores de medição.

A decomposição em valores singulares (SVD) teve início com os trabalhos de Beltrani em 1873, com os estudos de formas bilineares, aplicando a decomposição para matrizes quadradas não singulares com valores singulares distintos, e Jordan 1974 com a redução de formas bilineares para formas diagonais através de substituições ortogonais. Destaque-se, também o trabalho de James Joseph Sylvester, em 1889, com a aplicação à matrizes reais, nomeando os valores singulares por multiplicadores canônicos. Posteriormente, no ano de 1939, Eckart e Young desenvolveram a aplicação da SVD aplicada a matrizes retangulares.

A técnica de decomposição em valor Singular (SVD) tem aplicações em diversas áreas, como por exemplo em telecomunicações, onde a SVD é usada como ferramenta para a redução da dimensionalidade dos dados a serem transmitidos (VRABIE, *et al.*, 2003).

Ainda na área de tratamento de sinais. Bai *et al.*, (2008) utilizaram a técnica SVD para o tratamento de imagens utilizadas em fMRI (*functional Magnetic Resonance Imaging*), aplicada juntamente com a ICA de modo a reduzir a dimensionalidade dos sinais.

Quanto a avaliação das interações presentes no sistema e visto que essas interações, presentes nas variáveis de processo, são de grande importância na diferenciação entre os sistemas MIMO e sistemas SISO. Sabendo que um sistema MIMO, com a presença de um pequeno grau de interação, pode ser projetado como um sistema Multi-SISO. Esse tipo de consideração torna o projeto de controle mais fácil, visto que cada variável pode ser considerada independente das outras variáveis de processo (TRIERWEILER, 1997). Como critério de medição do grau de interação foi proposto por Bristol (1966) a utilização da Matriz de Ganhos relativos (RGA – *Relative Gain Array*), para a medição das interações entre todos os candidatos a pares de controle nos sistemas SISO.

Como os sistemas multivariados apresentam acoplamento natural entre as suas variáveis de entrada e saída, estudo de estruturas de desacoplamento, torna-se uma das mais importantes etapas para a determinação do sistema de controle descentralizado. Segundo Ogunnaike (1994)

o acoplamento pode ser dividido em duas formas: Acoplamento direto e acoplamento cruzado. Ainda segundo o Ogunnaike, o acoplamento direto é a forma desejada de que os acoplamentos apareçam nos sistemas, pois permite que o mesmo possa ser controlado de forma mais simples (OGUNNAIKE, 1994). Diante do exposto as estruturas de desacoplamentos têm como objetivo eliminar os efeitos dos acoplamentos cruzados entre as variáveis, permitindo a utilização dos sistemas de malhas do tipo SISO.

3.1. Estado da Arte

Yingwei e Yang (2010) propuseram uma otimização por PSO (*Particle Swarm Optimization*) chamado PSO-ICA, com a finalidade de monitoramento estatístico de processo multivariado (MSPM), utilizando essa nova abordagem para extrair alguns componentes independentes dominantes dos dados normais do processo. Esse método foi aplicado a detecção de falhas e no diagnóstico do “Tennessee Eastman Process”, estimando eficazmente os componentes independentes e obtendo uma solução mais precisa.

Sudibyo *et al.* (2012) utilizou a planta de destilação reativo do Éter metil-terc-butílico como estudo de caso comparativo entre o modelo de controle MIMO, através de *Model Predictive Control* (MPC) e com a metodologia de desacoplamento PI (Proporcional – Integral) para o controle de pureza do MTBE (*Methyl Tert-butyl Ether*) e da conversão de isobuteno, com a manipulação da carga do reboiler e do vazão de refluxo respectivamente. Segundo o autor, o desempenho de ambos os controladores foi medido através da utilização do IAE (*Integral Absolute Error*), ISE (*Integral Squared Error*), ITAE (*Integral of the Time-Weighted Absolute Error*), mostrando que o controle MIMO MPC foi mais eficiente, quando comparado ao controlador PI desacoplado.

Chen *et al.* (2013), demonstraram que técnicas baseadas em ICA utilizadas no monitoramento do processo de separação de ar criogênico, apresentou um diagnóstico de falhas no bem mais satisfatórios quando comparados a aplicação da técnica PCA no mesmo processo.

Yung-Kun Chuang *et al.* (2014) propôs uma combinação entre a análise de componente independente (ICA) com o espectro NIR (*Near Infrared*) para quantificar a qualidade interna do arroz. No trabalho, foi verificado que a ICA junto com a espectroscopia de infravermelho próximo (NIR) pode distinguir a “frescura” do arroz servindo como método de análise, não destrutiva, por rastreamento rápido.

Em seu trabalho Carmo (2014) mostrou ser possível a utilização da técnica ICA para o desacoplamento multivariável em malhas de controle, possibilitando um entendimento melhor dos emparelhamentos entre as variáveis controladas e manipuladas, estabelecendo uma melhor estrutura de controle. Ainda segundo a autora, a técnica ICA permitiu obter a separação de sinais, tornando as variáveis independentes, e com isso, obteve um melhor desempenho do sistema de controle, quando comparado ao método convencional de controle utilizado em grande parte dos processos industriais.

Lianfang *et al.* (2014) propôs a utilização do método KTSICA (*Kernel Time Structure Independent Component Analysis*), para resolver a existência de mais de uma distribuição de Gauss presentes no problema de separação cega de fontes, aplicado no monitoramento de processos não-linear. Nesse estudo, os autores fazem uma comparação entre a técnica proposta com a KICA (*Kernel Independent Component Analysis*), mostrando que o método de identificação de falhas KTSICA superou a KICA, indicando maior eficiência, as variáveis de falha.

Bizon *et al.* (2016) apresenta uma aplicação da análise dos componentes independentes para imagens 2D de um ciclo de combustão luminosa. Nesse trabalho a técnica ICA foi empregado na identificação dos componentes espaciais e temporal durante os ciclos da combustão. Segundo os autores, a ICA, identificando as informações sobre a morfologia dominante das variações cíclicas, conseguiu obter as componentes espaciais e os coeficientes das imagens analisadas, essenciais para o estudo do comportamento transiente do processo.

O trabalho de Wang *et al.* (2016) a matriz de separação gerada pelo a ICA não preserva toda a informação da mistura, de modo que algumas informações podem ser perdidas. No estudo proposto pelos autores, uma estratégia “*Multi-block*” foi proposta para melhorar a eficiência do método ICA, indicando um modelo totalmente orientado a dados que divide matriz de mistura com base na generalização dos dados do coeficiente e combina os resultados de sub-blocos, utilizando inferência Bayesiana. Toda a informação contida na matriz de mistura é utilizada, possibilitando, uma melhor estimativa das componentes independentes e uma melhor capacidade de monitoramento de processos não gaussianos (WANG *et al.*, 2016).

Lu Xian *et al.* (2016) apresentam o estudo de uma nova metodologia que combina o EEMD (*Ensemble Empirical Model Decomposition*) e a ICA, aplicada à análise do preço do ouro. A técnica ICA é utilizada para decompor o VIMFs (*Virtual Intrinsic Model Functions*),

revelando uma decomposição do preço do ouro como combinação das ICs: desenvolvimento do mundo; oferta de ouro e demanda; dólar, inflação, emergências de mercado, geopolítica internacional e ciclicidade, possibilitando uma nova maneira de análise do preço do ouro a partir de uma nova perspectiva.

Apesar dos diversos trabalhos apresentarem modificações na metodologia ICA, assim como as aplicações nas mais variadas áreas, os problemas de amplitude e de fase ainda não estão resolvidos. Em algumas aplicações com a ICA, a magnitude das estimativas não influencia na verificação da tendência dos sinais fontes estimadas. No entanto, em outros casos, tais como controle de processo, e tratamento de sinais onde a precisão é importante, o estado da técnica ainda não respondem a essa necessidade.

Pordanjani e Xu (2016) demonstram que a utilização da técnica de decomposição de circuitos (CCT- *Channel Components Transform*) para o desacoplamento de redes de energia possui dificuldades em relação a robustez, devido a utilização da decomposição em valores próprios. Diante disto, os autores propuseram a utilização da SVD em substituição à técnica de EVD. A substituição proposta levou a obtenção dos mesmos resultados da técnica CCT-EVD, porém sem a presença das dificuldades já descritas (PORDANJANI e XU, 2016).

Soev *et al.* (2016) propôs no seu trabalho desenvolver um procedimento de desacoplamento baseando-se na utilização de métodos de decomposição de tensores, provocando uma dissociação estatística do sistema MIMO. De acordo com o autor, resultados obtidos, a partir de um modelo de frequência indicam que o procedimento é bastante robusto.

Al Hasanat *et al.* (2017) apresentou, em seu trabalho, um algoritmo de separação cega baseado na decomposição em valores singulares (SVD) com técnica para redução dimensões de matrizes, aplicado no estudo de ondas sísmicas. Esse algoritmo, foi utilizado como ferramenta para transformar campos de ondas multicomponentes em um único vetor de dados, facilitando assim a análise de ondas sísmicas de múltiplos componentes ruidosos. Segundo o autor, o algoritmo desenvolvido, teve capacidade de identificar diferentes campos de ondas, a partir de informações de energia.

4. FUNDAMENTAÇÃO TEÓRICA

4.1. Análise de Componentes Independentes

A análise de componentes independentes é uma técnica estatística utilizada para encontrar componentes independentes referentes a um conjunto de variáveis aleatórias. A partir de um vetor aleatório $X = [X_1, X_2, \dots, X_n]^T$, cujo n elementos são sinais misturados de n componentes estatisticamente independentes entre si de um vetor aleatório $S = [S_1, S_2, \dots, S_n]^T$. Dessa forma, o modelo ICA expressa cada X_i , para $i = 1, 2, \dots, n$, como uma combinação linear dos componentes independentes, dada por:

$$X_i = a_{i1}S_1 + a_{i2}S_2 + \dots + a_{in}S_n, \quad \text{para } i = 1, 2, \dots, n \quad (4.1)$$

em que a_{ij} , i e $j = 1, 2, \dots, n$, são coeficientes reais.

Como uma combinação linear, o modelo também pode ser escrito como:

$$X_i = \sum_{j=1}^n a_{ij}S_j \quad (4.2)$$

Usando uma notação matricial, a equação (4.2) pode ser expressa por:

$$X = AS \quad (4.3)$$

em que o termo A pondera a mistura dos sinais fontes. A matriz A é denominada matriz de mistura.

O modelo ICA geral, descreve como os dados observados são gerados através do processo de mistura das componentes S_i . Para ilustrar o modelo ICA, utiliza-se o problema de *Cocktail Party*, que trata da captação de n sinais de áudios de diversas fontes S_n , por sensores de áudio que geram sinais misturados X_n , como mostra a Figura 1.

Pelo o Modelo ICA, e de acordo com a Figura 1, a variável de saída dos sensores (X_i) é proveniente da mistura dos sinais oriundos dos blocos S_i . Matematicamente a variável aleatória X_i pode ser escritas na forma da Equação (4.4).

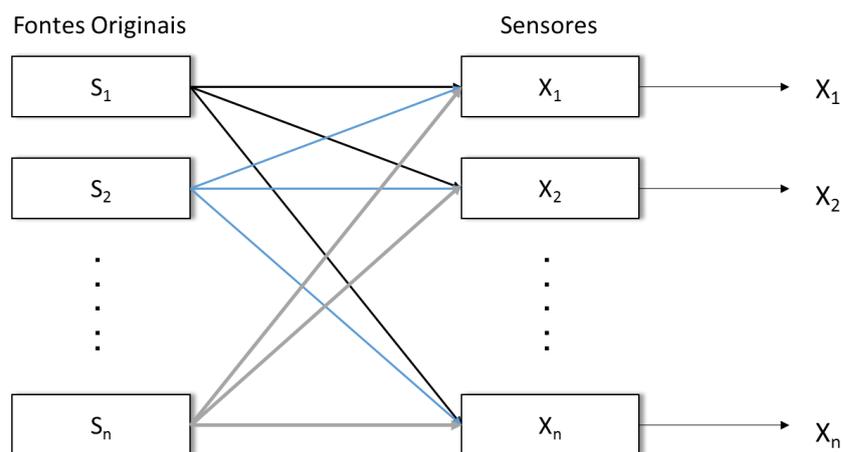
$$X_1 = \sum_{J=1}^n a_{1J} S_J \quad (4.4)$$

$$X_n = \sum_{J=1}^n a_{nJ} S_J \quad (4.5)$$

Na forma Matricial:

$$\begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_n \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \cdots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nn} \end{bmatrix} \begin{bmatrix} S_1 \\ S_2 \\ \vdots \\ S_n \end{bmatrix} \quad (4.6)$$

Figura 1– Problema *Cocktail Party*.



Fonte: Própria

A intenção da técnica ICA é estimar as componentes independentes, partindo do pressuposto que não se conhece valores dos coeficientes de mistura e das componentes independentes, ou seja, tem-se que estimar uma matriz \mathbf{W} composta por vetores linhas \mathbf{w}_i , onde $i = 1, \dots, n$ tal que:

$$S = \mathbf{W}X \quad (4.7)$$

Como não se tem conhecimento acerca da matriz \mathbf{A} , não se pode encontrar uma matriz \mathbf{W} que satisfaça a equação (4.7). Entretanto, pode-se encontrar uma matriz \mathbf{W}^* tal que:

$$Y = W^* X, \quad \text{onde } \|S - Y\| = \min. \quad (4.8)$$

A modelagem apresentada anteriormente corresponde a estrutura clássica desenvolvida para o ICA, tendo a sua efetividade no cumprimento de algumas exigências como: não-gaussianidade, independência dos sinais.

4.2. Ambiguidade da análise do ICA

O modelo de análise de componentes independentes (ICA) possui duas ambiguidades inerentes a serem consideradas: não se pode determinar a variância das componentes independentes (Ambiguidade de Magnitude) e não é possível determinar a ordem dessas componentes independentes (Ambiguidade de Permutação) (NAIK, 2012).

- Ambiguidade de Magnitude

A ambiguidade de magnitude é devida fato de que por ambas as variáveis S e A serem desconhecidas, qualquer escalar que se possa multiplicar umas das fontes poderá ser cancelado pela divisão de uma das colunas da matriz de mistura (A). Segundo Hyvarinen e Oja (2000) uma solução para a correção das amplitudes das componentes independentes é assumir que cada componente tem variância unitária, visto que estas são componentes aleatórias.

- Ambiguidade de Permutação

A razão para a existência dessa ambiguidade é também o fato de que, ambas as variáveis S e A são desconhecidas. Podendo a soma da equação (4.2) alterar, livremente, a ordem das componentes independentes. Caso seja inserido uma matriz de permutação P e a sua inversa P^{-1} na equação de mistura dos sinais, equação (4.3), tem-se: $X = AP^{-1}PS$, causa apenas o surgimento de uma nova matriz de mistura AP^{-1} e uma nova matriz de sinais originais a serem estimadas pelo o modelo ICA. Segundo Naik (2012), esse tipo de ambiguidade é inerente dos processos de separação cega de fontes (BSS), não podendo ser imposta qualquer restrição quanto a ordem do sinal separado. Assim, todas as permutações dos sinais fontes são igualmente válidas.

4.3. Restrições do Modelo ICA

Para que o modelo ICA seja efetivo é necessário, que os componentes S_i a serem estimados, cumpram algumas exigências como: Ser não-gaussianos; independentes entre si; e que sua matriz de mistura seja quadrática.

4.3.1. Não – Gaussianidade

Sabe-se que os cumulantes de alta ordem da distribuição gaussiana são zero, sendo essa informação essencial para a estimação do modelo ICA. Portanto é impossível estimar as componentes independentes se as mesmas são gaussianas. A estimação da não-gaussianidade dos sinais, pode ser realizada a partir da cumulantes/momentos de quarta ordem ou pela entropia dos sinais.

4.3.1.1. Não-gaussianidade por Kurtosis

A *Kurtosis* é um método clássico de medida do caráter gaussiano do sinal. Esse parâmetro é equivalente ao momento de 4ª ordem dos dados analisados. Considerando um sinal real “ S ” e assumindo que o mesmo tem média zero, a determinação dessa estatística pode ser feita por:

$$kurt(s) = E\{s^4\} - 3(E\{s^2\})^2 \quad (4.9)$$

Para o caso do sinal ser gaussiano, tem-se que seu valor será zero, pois o valor esperado da variável aleatória de 4ª ordem pode ser igual a 3 vezes ao produto do valor esperado de 2ª ordem, onde:

$$E\{s^4\} = 3(E\{s^2\})^2 \quad (4.10)$$

Para o caso dos dados serem branqueados, onde as variáveis serão descorrelacionados e terão variância unitária, observa-se que a *kurtosis* é aproximada à expressão:

$$kurt(s) = E\{s^4\} - 3 \quad (4.11)$$

Para o caso em que os sinais apresentados sejam não-gaussianos, o valor da *Kurtosis* será diferente de zero. Para valores negativos, tem-se que a distribuição de densidade é conhecida como subgaussianas. Para valores positivos, essa distribuição é denominada de supergaussianas. Quanto maior for a diferença, em modulo, do valor da *Kurtosis* em relação a

zero, maior será a não-gaussianidade do sinal observado, permitindo uma melhor separação dos sinais.

4.3.1.2. Não-gaussianidade por Entropia/Negentropia

Entropia é um conceito proveniente da teoria de informação, sendo uma medida da incerteza média associada à observação de uma variável aleatória (COVER; THOMAS, 1991). Quanto maior for o grau de “imprevisibilidade” da variável, maior será a sua entropia. Outra maneira utilizada para quantificar a não gaussianidade é a partir da negentropia, sendo esse termo baseado na quantidade de informação da entropia diferencial. Pode-se definir a entropia diferencial (H) a partir da Equação 4.12.

$$H(Y) = -\int_y f_Y(y) \ln f_Y(y) dy \quad (4.12)$$

sendo Y uma variável aleatória e $f_Y(\cdot)$ uma função de densidade.

Uma variável gaussiana possui a maior entropia entre variáveis de mesma variância (HYVÄRINEN, 2001). Logo, a entropia pode ser usada, para o cálculo da não-gaussianidade, da seguinte maneira:

$$J(Y) = H(Y_{gauss}) - H(Y) \quad (4.13)$$

onde $J(\cdot)$ é a negentropia de Y .

Utilizando a Equação 4.13 para o cálculo da entropia e conseqüentemente a negentropia, obtém-se sempre um valor positivo, responsável por indicar a diferença de entropia entre uma variável gaussiana e uma variável observada com os mesmos parâmetros. Como o cálculo da negentropia requer um tempo computacional muito grande, é utilizado, na maioria das vezes, aproximações para essa estimativa. Uma dessas aproximações é mostrada a seguir:

$$J(Y) \approx \sum_{i=1}^p k_i [E\{G_i(Y)\} - E\{G_i(v)\}] \quad (4.14)$$

onde k_i é uma constante, v uma variável gaussiana com média zero e variância unitária e Y a variável, de media zero e variância 1, à ser calculada. O termo G_i representa uma função não-quadrática que não “cresça muito rapidamente”. Algumas dessas funções são mostradas nas equações 4.15, 4.16, 4.17.

$$G_1(Y) = \frac{1}{\alpha_1} \log \cosh(\alpha_1 Y) \quad 1 \leq \alpha_1 \leq 2 \quad (4.15)$$

$$G_2(Y) = -\exp\left(-\frac{Y^2}{2}\right) \quad (4.16)$$

$$G_3(Y) = \frac{Y^4}{4} \quad (4.17)$$

Mostrado todo a definição e/ou procedimento para a utilização da entropia/negentropia, tem-se que a sua maximização é semelhante a maximização da não-gaussianidade das fontes. Todavia, a maximização das fontes seria buscar a minimização das entropias marginais das estimativas das fontes (DAMASCENO, 2010).

4.3.2. Independência Estatística

Duas variáveis aleatórias Y_i e Y_j são ditas independentes se a informação contida na variável Y_i não fornece nenhuma informação sobre a probabilidade de ocorrência da variável Y_j . Segundo ainda a estatística, independência é determinada em termos das densidades de probabilidade, isto é:

$$f(y_1, y_2, \dots, y_n) = f_1(y_1)f_2(y_2)\dots f_n(y_n) \quad (4.18)$$

em que $f_i(y_i)$ denota a densidade marginal de Y_i .

Como, para o caso da análise de componentes independentes, não se tem conhecimento das fontes a serem estimadas, não há como estimar diretamente a suas funções distribuições de probabilidade. Para contornar essa problemático, pode-se fazer uso dos princípios matemáticos da Correlação/descorrelação para caracterizar uma determinada distribuição, fazendo as estimativas dos valores esperados, a partir das misturas como única informação disponível.

A ausência de correlação, entre as variáveis, é usada como uma evidência para a independência entre as variáveis aleatórias. Entretanto essa evidência não garante a independência entre essas variáveis. Segundo Leite (2004), se duas variáveis aleatórias forem independentes, logo elas são descorrelacionadas, entretanto se as mesmas são descorrelacionadas, não serão, obrigatoriamente independentes. Matematicamente, tem-se que a descorrelação é determinada quando:

$$\text{Cov}(Y_i, Y_j) = E(Y_i Y_j) - E(Y_i)E(Y_j) = 0 \quad (4.19)$$

$$E(Y_i Y_j) = E(Y_i)E(Y_j)$$

4.3.3. Matriz de Mistura Quadrada

O método de separação ICA presume que a matriz de mistura é quadrática, isto é, que o número de componentes independentes estimados é o próprio número de dados observados. Caso haja mais misturas que fontes, é possível excluir as misturas redundantes.

Entretanto, caso o número de fontes seja maior que o número de misturas, encontrar a matriz de mistura não será suficiente para a resolução do problema de separação.

4.4. Algoritmo ICA utilizando PCA

Um algoritmo, desenvolvido recentemente, provou ser superior a algumas abordagens ICA (KUN e CHAN, 2006). Denominado como ICA por PCA, esta abordagem resolve o problema de BSS linear a partir da aplicação de PCA seguindo de uma transformação para a recuperação dos sinais fontes.

Partindo dos dados X , PCA e ICA buscam encontrar uma transformação linear da equação (4.8). Entretanto se baseiam em critérios diferentes. O PCA tem como objetivo encontrar uma ortogonal W responsável por fornecer saídas não correlacionadas. Em outras palavras, o PCA apenas usa a distribuição gaussiana conjunta para ajustar os dados encontrando uma transformação ortogonal com o objetivo de fazer a distribuição conjunta de Gauss fatorável independente da verdadeira distribuição dos dados (KUN e CHAN, 2006).

Para a ICA, tem-se que este, busca uma transformação linear que torna favorável a verdadeira distribuição dos dados transformados, de modo que as saídas são mutualmente independentes. Falando de maneira estatística, a independência mútua é muito mais “forte” do que a não-correlação entre as variáveis (KUN e CHAN, 2006).

De maneira geral, Kun e Chan (2006) demonstrou que as componentes independentes têm diferentes *Kustosis*, possibilitando a seguinte proposição:

- Dados s , v , e z vetores aleatórios tal que $v = Ws$, onde W é uma matriz ortogonal e $z = \frac{1}{\|v\|}v$. Suponha que s tem média zero e que as componentes independentes têm diferentes *Kurtosis*. Então, a matriz ortogonal U que é dada pela componente principal de z (z não é centralizado) realiza ICA em v .

A metodologia ICA por PCA se resume nas seguintes etapas de cálculo:

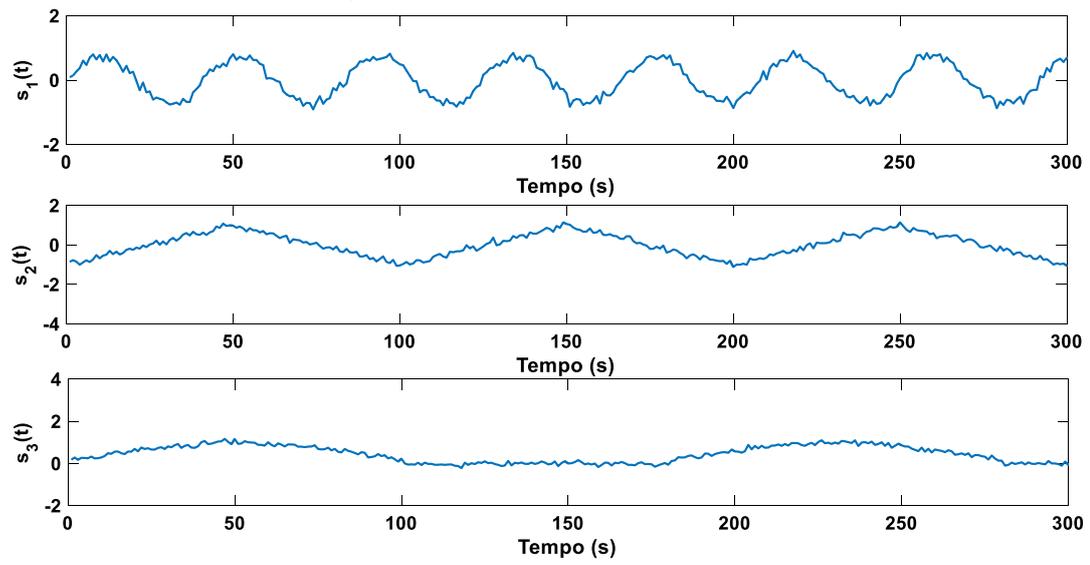
- Branqueamento de x ;
- Faça uma transformação $z = \frac{1}{\|v\|}v$;
- Encontre U usando PCA em z ;
- Depois de encontrar a matriz ortogonal U finalmente a matriz de separação pode ser estimada usando a expressão $W = UV$.

4.4.1. Problemas envolvendo a estimação pela ICA por PCA

Como a técnica ICA por PCA assume que as fontes possuem diferentes distribuições e, por ser baseado em Diferentes *Kurtosis* possui, sensibilidade a *outliers*. Kun e Chan (2006) mostraram, em seu trabalho, que esse pressuposto afeta o desempenho da separação, ao ponto que, com a aproximação dos valores de *Kurtosis* a metodologia ICA por PCA não consegue separar os sinais fontes. Nesse mesmo trabalho, também foi mostrado que o desempenho da técnica ICA por PCA torna-se pior com o aumento do número de fontes. Segundo os autores, pode haver duas razões para este fenômeno. Em primeiro lugar, como o número de fontes aumenta, as diferenças entre as distribuições tornam-se cada vez mais insignificantes. Em segundo lugar, devido ao efeito das amostras finitas, as fontes podem não ser completamente independentes (KUN e CHAN, 2006).

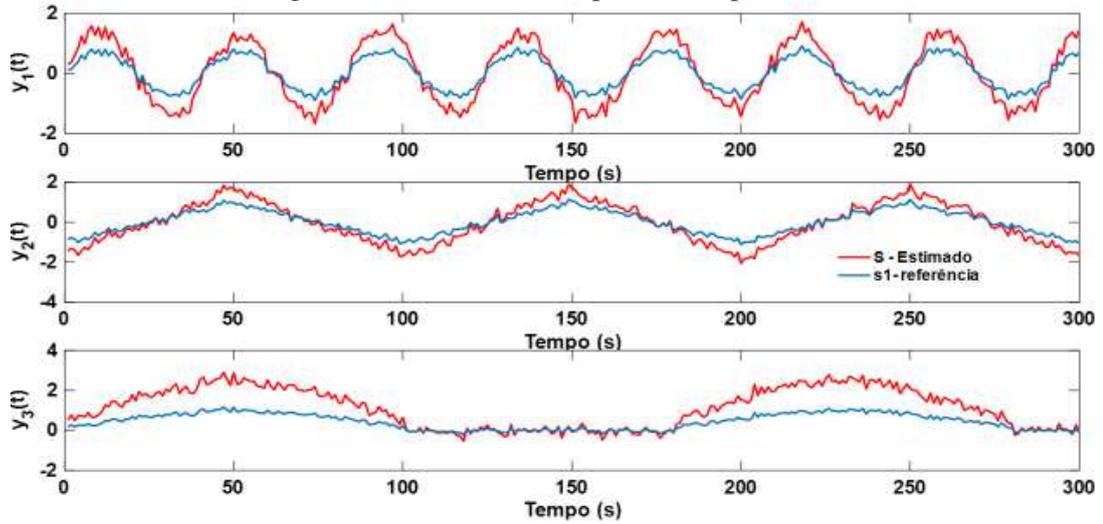
No trabalho de Damasceno (2013) foi mostrado que o sinal estimado pela a técnica ICA por PCA possui diferença, em alguns casos, de amplitude e fase quando comparados aos sinais fontes de referência. As Figuras 2 e 3 mostram essas diferenças.

Figura 2 - Sinais fontes de Referência.



Fonte: Própria

Figura 3 - Sinais estimados pelo o ICA por PCA.



Fonte: Própria

4.5. Algoritmo *FastICA*

Esse algoritmo foi publicado por Hyvarinen (1999b), tendo como objetivo encontrar uma matriz W com suas linhas w_i^t ajustadas de modo que, a relação $y_i = w_i^t x$ resulte na estimativa das fontes, tendo em vista que a maximização da Negentropia é baseada nos momentos polinomiais (HYVARINEN, 1999a). Considerando a aproximação pela a Negentropia e que os dados utilizados foram, previamente branqueados, essa maximização resulta em encontrar uma matriz W que é descrito pelo seguinte problema de otimização (HYVARINEN, 2000):

$$\hat{w}_i = \arg \max (E\{G(y_i)\} - E\{G(x_g)\})^2 \quad (4.20)$$

O máximo da equação 4.20 é obtido quando é encontrado o valor ótimo de $E\{G(y_i)\}$, sendo o termo $E\{G(x_g)\}$ constante (DAMASCENO 2010). Assim, observando para o primeiro termo da equação 4.20, a maximização coincide com um problema de otimização. Segundo Hyvarinen (1999), esse problema de otimização é resolvido usando o método de Lagrange, quando a seguinte condição é satisfatória (HYVARINEN, 1999):

$$E\{xG'(w_i^t x)\} + \beta w_i = 0 \quad (4.21)$$

onde β é uma constante.

Partindo do princípio que as misturas foram branqueadas, pode-se aplicar o método de Newton para a solução da Equação (4.21), tendo como regra de atualização a seguinte Equação:

$$\begin{aligned} \hat{w}_i &\leftarrow E\{xG(w_i^t x)\} - E\{G'(w_i^t x)\}w_i \\ \hat{w}_i &\leftarrow \frac{w_i}{\|w_i\|} \end{aligned} \quad (4.22)$$

onde o termo G' representa uma função não linear, derivada das funções não-quadráticas G (equações 4.15, 4.16 e 4.17), mostradas na sessão 4.2.1. Suas derivadas são mostradas nas Equações 4.23, 4.24 e 4.25.

$$G_1'(Y) = \tanh(\alpha_1 Y) \quad (4.23)$$

$$G_2'(Y) = Y \exp\left(-\frac{Y^2}{2}\right) \quad (4.24)$$

$$G_3'(Y) = Y^3 \quad (4.25)$$

4.6. Algoritmo JADE

O algoritmo de Diagonalização Conjunta Aproximada de Automatrizes (JADE) foi proposto por Cardoso *et al.* (1993) para solucionar o problema da Separação cega de fontes. A principal restrição utilizada pelo o algoritmo JADE, para o problema de BSS é que as fontes a serem separadas sejam estatisticamente independentes. Esse algoritmo busca a independência através de cumulantes de 4ª ordem, reduzindo o conjunto de dados observados a um conjunto de estatísticas.

Um das principais vantagens apresentado pelo JADE é a capacidade de se mover em passos macroscópicos através do espaço de parâmetros, solucionando o problema causado pela escolha incorreta do passo de adaptação, comum em algoritmos que utilizam técnicas como o gradiente natural (CICHOCKI, 2002). Por outro lado, a sua implementação computacional apresenta grande complexidade, principalmente no que diz respeito aos cálculos das estatísticas de ordem superior. O Algoritmo JADE pode ser resumido nos seguintes tópicos:

- Encontrar a matriz de branqueamento Q ;
- Branquear os dados coletados, utilizando a Equação 4.26.

$$z(k) = Qx(k) \tag{4.26}$$

- Estimar as matrizes de cumulantes;
- Minimizar o critério de diagonalização conjunta, ou seja, tornar os matrizes de cumulantes tão diagonais quanto o possível.
- Determinar a matriz de mistura A e estimar os componentes independentes de acordo com a Equação 4.27.

$$y(k) = U^T z(k) \tag{4.27}$$

4.7. Pré – Processamento do Sinal

Em virtude das restrições e ambiguidades presentes nos modelos de separação por análise de componentes independentes. É necessário que seja realizado um pré-tratamento dos sinais a serem separados. Essa etapa, se divide em: Centralização e Branqueamento, é utilizada

para diminuir a complexidade e melhor condicionar o problema da análise de componentes independentes.

4.7.1. Centralização

O procedimento de centralização, aplicado a ICA é um dos procedimentos mais básico e necessário para simplificar a separação, pelos os algoritmos de ICA. Essa centralização é realizado com a simples retirada do valor médio $\mathbf{m} = \mathbf{E}(\mathbf{x})$, deixando o sinal misturado X com média zero e conseqüentemente deixando S também com média zero (Equação 4.28). Esse procedimento é realizado no intuito de facilitar as etapas de estimação. Como no caso de algoritmos que utilizam a *Kustosis* como medida de não-gaussianidade. E atendendo algumas restrições dos próprios algoritmos. A equação (4.28) mostra o processo de centralização.

$$X_c = X - m \quad (4.28)$$

4.7.2. Branqueamento

Outra etapa importante e estratégica para a separação por ICA é o branqueamento das variáveis observadas. O processo de branqueamento envolve uma transformação linear, tal que os vetores observados serão descorrelacionados e de variância unitária. (HYVÄRINEN; OJA, 2000). Um vetor linha z_i da matriz dos sinais é dito branco se ele satisfaz a seguinte relação:

$$E\{zz^T\} = I \quad (4.29)$$

onde a equação (4.29) é a matriz de covariância do vetor z_i . Ou seja, um vetor z é dito Branco se a sua matriz de covariância é igual a matriz identidade. A obtenção desse tipo de variável é possível graças a uma transformação linear na forma:

$$z = Vx \quad (4.30)$$

onde z é o vetor de variáveis brancas e V é chamada de matriz de branqueamento. Um método simples de Branqueamento é através da técnica *eigenvalues decomposition* (EVD) na matriz de covariância de X (HYVÄRINEN; OJA, 2000). De acordo com esse tipo de decomposição. A matriz de branqueamento é definida como:

$$V = ED^{-1/2}E^T \quad (4.31)$$

onde E é a matriz ortogonal de autovetores e D é a matriz diagonal de autovalores provenientes da utilização do EVD (eigenvalues decomposition) na matriz de covariância $\mathbf{E}\{\mathbf{X}\mathbf{X}^T\}$.

A utilização da Decomposição em Autovalores (EVD) tem como utilidade, a transformação da matriz de mistura A em uma nova matriz \hat{A} com características de matriz ortogonal. A Combinação das equações (4.3) e (4.30) mostra a obtenção da matriz A na forma ortogonal.

$$z = ED^{-1/2}E^T AS = \hat{A}S \quad (4.32)$$

Conseqüentemente o processo de branqueamento reduz o número de parâmetros a serem estimados de n^2 da matriz de mistura original A , para $(n-1)/2$ parâmetros da nova matriz \hat{A} .

Mostrado os passos necessários para a realização do processo de branqueamento, e ainda a importância de realizar essa etapa de processamento, foi identificado a necessidade de aprofundar os estudos em relação ao branqueamento dos sinais, e conseqüentemente melhorar a convergência dos Algoritmos de Análise de componentes independentes.

Uma melhoria no processo separação de sinais pode ser realizada na etapa de branqueamento, onde a possível inserir um termo de ponderação na matriz de branqueamento V (Equação 4.31). Na tentativa de provocar uma melhoria na matriz V foi proposto, a inserção do termo $1/\sqrt{n}$, considerando a teoria das matrizes circulantes. Onde de acordo com Zhang (1999), uma matriz é dita circulante se os elementos triangulares inferiores são simétricos aos elementos triangulares superiores da mesma matriz (ZHANG, 1999). Dessa forma, a matriz de branqueamento (Equação 4.31) pode ser reescrita na forma apresentada na equação (4.33).

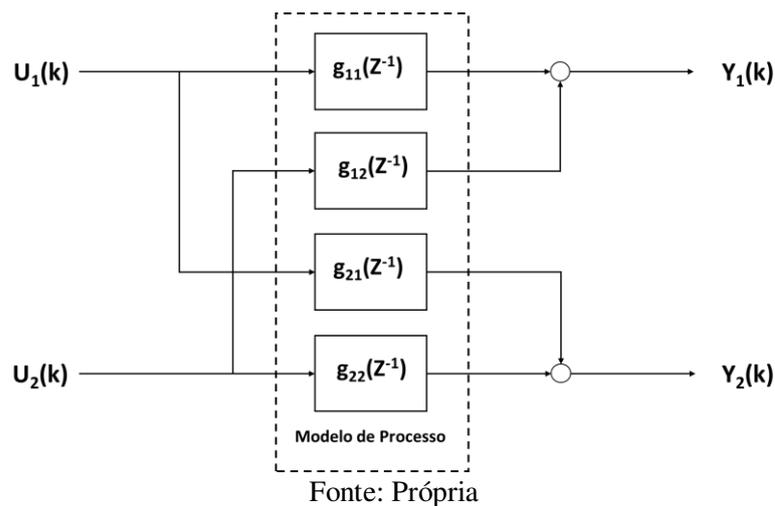
$$z = \frac{1}{\sqrt{n}}Vx \quad (4.33)$$

A utilização do termo de correção, proposto nesse trabalho, junto a metodologia ICA por PCA clássica foi denominada de MOD-ICA

4.8. Processos Multivariados

A maioria das aplicações com controle de processo industrial, envolvem um conjunto de variáveis de entrada (variáveis manipuladas) e outro conjunto de variáveis de saída (variáveis controladas), sendo esse tipo de aplicação chamada de sistema MIMO (*Multiple Input – Multiple Output*). (ANJOS e SILVA, 2016). O sistema MIMO pode ser exemplificado, considerando um sistema 2x2, na Figura 4, onde as variáveis de processo, Y_1 e Y_2 sofrem a influência simultâneo das duas variáveis manipuladas, através das informações transmitidas pelas as funções de transferência G_{12} e G_{21} . Nesse caso, quanto maior for a interferência descrita pelas funções de transferência G_{12} e G_{21} , nas variáveis de processo, Y_1 e Y_2 , maior será o nível de acoplamento do sistemas, provocando uma maior dificuldade na aplicação das técnicas convencionais de controle.

Figura 4 - Exemplo de interação entre as variáveis do processo multivariável.



De maneira geral, e de acordo com o que foi apresentado na Figure 4. A dinâmica do processo, em relação as variáveis de saída, pode ser representada pela as Equações 4.34 e 4.35.

$$y_1(k) = g_{11}(z^{-1})u_1(k) + g_{12}(z^{-1})u_2(k) \quad (4.34)$$

$$y_2(k) = g_{21}(z^{-1})u_1(k) + g_{22}(z^{-1})u_2(k) \quad (4.35)$$

De acordo com a equação (4.34) e equação (4.35) qualquer mudança nos sinais U_1 e U_2 compromete ambas as saídas. É devido, a esse tipo de característica, à procura de técnicas, matemáticas que façam com que a influência das funções de transferência G_{12} e G_{21} sejam eliminadas ou minimizadas. Uma das alternativas para isso, é a aplicação de técnicas de desacoplamento.

4.8.1. Análise dos Sistemas Multivariáveis

Alguns tipos de processo apresentam estruturas que os tornam pobre candidatos para o desacoplamento (ALTEN, 1994; OGUNNAIKE AND RAY, 1995; ASMAR, 1999). Consequentemente, deve-se realizar uma análise prévia de algumas características do processo tais como a controlabilidade, grau de interação entre malhas e grau de condicionamento para o desacoplamento.

4.8.1.1. Controlabilidade

A controlabilidade é definida para um selecionado conjunto de variáveis manipuladas e variáveis controláveis. Sendo assim, para um processo multivariável qualquer, a controlabilidade pode variar de acordo com o subconjunto de variáveis escolhido. Se utilizando das seguintes relações de regime permanente:

$$y_1(k) = K_{11}(z^{-1})u_1(k) + K_{12}(z^{-1})u_2(k) \quad (4.36)$$

$$y_2(k) = K_{21}(z^{-1})u_1(k) + K_{22}(z^{-1})u_2(k) \quad (4.37)$$

Uma indicação da interação do sistema pode ser obtida quando a variação do comportamento do sistema muda de acordo com os ajustes das variáveis manipuladas. A inversa da matriz de ganhos K^{-1} permite determinar se o sistema é controlável ou não. Caso a inversa exista, e seu determinante seja diferente de zero, o sistema é dito controlável.

$$u_i(k) = K^{-1}y_i(k) \quad (4.38)$$

4.8.1.2. Grau de interação nas variáveis do processo

O grau de interação nas variáveis de processo, pode ser calculado através da obtenção do indicador: matriz de ganhos relativos (RGA). A técnica RGA foi proposta por Bristol (1966) e é bastante utilizada na seleção dos pares das variáveis de entrada e saída, com o objetivo de selecionar configurações com o mínimo de interação possível.

Essa técnica consiste em uma matriz em que seus termos são razões entre o ganho estático de cada par input-Output, em malha aberta, e o ganho do mesmo par quando os outros pares estão em malha fechada (ANJOS e SILVA, 2016). As interações medidas com o levantamento do ganho relativo adimensional I_{ij} , de acordo com a equação (4.39)

$$I_{ij} = \frac{\left(\frac{\delta y_i}{\delta u_j} \right) \text{ todas as malhas abertas}}{\left(\frac{\delta y_i}{\delta u_j} \right) \text{ todas as malhas fechadas, excluindo a malha } u_j} \quad (4.39)$$

Fazendo uma análise breve em relação ao ganho relativo adimensional mostrado na equação (4.39), tem-se que valores iguais a 1 indica que o ganho em malha aberta não sofre influência dos outros ganhos em malha fechada, logo não há interação entre as malhas e mais desacoplado será o sistema. Valores menores de que 0 indicam impossibilidade de controle e $0 < I_{ij} < 1$, indica que a interação entre as malhas.

4.8.1.3. Decomposição por valor singular (SVD)

Pode-se definir valores singulares, σ_i , como indicadores da proximidade que tem uma matriz da singularidade, constituindo-se como os limites dos possíveis ganho de G_p .

Esse método é muito útil para a análise de sistemas multivariáveis, principalmente, por ter a possibilidade de determinar as variáveis que mais influenciam na operação, além de determinar se o sistema possui interação entre as malhas (SVRCEK *et al.*, 2006). A técnica SVD consiste em expressar a matriz de ganho estático do processo G na forma:

$$G = USV^T \quad (4.40)$$

Onde G é a matriz de ganhos estáticos, U é uma matriz ortogonal, cujas colunas contém os vetores singulares de saída pela a esquerda e V é uma matriz ortogonal, cujas colunas representam os vetores singulares de entrada pela a direita. Devido a decomposição da matriz de ganho estacionário, demonstrada na Equação (4.40), os vetores coluna da matriz U ortogonal, indicam a direção na qual o processo apresenta maior sensibilidade, ou seja, o vetor u_1 indica a direção em que as PV's variam mais facilmente, enquanto os vetores u_2, \dots, u_n são responsáveis por indicar direções cada vez menos sensíveis.

De maneira análogo, os vetores colunas na matriz V apresentam em que sentido as MV's afetam o sistema, sendo o vetor v_1 aquele que indica a direção que mais influencia a processo e

os vetores v_2, \dots, v_n indicando direções menos influentes. Os componentes da matriz diagonal S representam os valores singulares, distribuídos em ordem decrescente.

Diante disto o emparelhamento entre PV – MV é definido pelo o cruzamento entre os valores absolutos das colunas das matrizes U e V . Onde o valor máximo do vetor u_i é emparelhado com o valor máximo do vetor v_i . Os outros emparelhamentos seguem a ordem decrescente de valores entres os outros vetores das matrizes U e V . A equação (4.41) resume o processo de emparelhamento pela a técnica SVD.

$$PV_i |_{\max(\text{abs}(u_{i,k}))} \Leftrightarrow MV_j |_{\max(\text{abs}(v_{i,k}))} \quad (4.41)$$

Onde $PV_i |_{\max(\text{abs}(u_{i,k}))}$ representa a variável de processo que tem maior valor absoluto do vetor u_k da matriz U e $MV_j |_{\max(\text{abs}(v_{i,k}))}$ representa a variável manipulada que tem maior valor no vetor v_k da matriz V .

4.8.1.4. Número Condicionante

O número condicionante, g_c , funciona como um indicador confiável do grau de condicionamento para o modelo do processo, de forma que nenhum outro, como exemplo: RGA, ou o grau de sensibilidade, fornecido por $|K|$, pode determinar (LUYBEN, 1990; ASMAR, 1999). Esse número foi definido por, Joseph e Brosilow (1978); Grosdidier *et al.* (1985) e Nett e Manousiouthakis (1987), como sendo a relação das grandezas do valor singular máximo e mínimo, de acordo com a equação (4.42). Sendo também uma medida da dificuldade da implementação do controle desacoplado para o problema em questão (MOORE, 1986).

$$g_c = \frac{S_{Max}}{S_{Min}} \quad (4.42)$$

4.9. Desacoplamento de processos multivariados

A utilização de sistemas de desacoplamento tem como função principal, eliminar ou atenuar a influência entre duas ou mais variáveis de um sistema MIMO. Essa influência é gerada naturalmente devido as relações intrínsecas entre as variáveis do processo em questão. A essência dos métodos de desacoplamento é introduzir dinâmicas que cancelem as interações existentes entre as variáveis do processo, permitindo que seja feito um controle independente

para cada uma das malhas do sistema (GARRIDO; VAZQUES; MORILLA, 2011). O processo de desacoplamento pode ser dividido em:

- 1) Desacoplamento dinâmico: Consiste na eliminação de todas as interações nas malhas de controle, em cada instante de tempo (em todas as frequências).
- 2) Desacoplamento de regime permanente: Tem como função eliminar somente as interações de regime permanente de todas as malhas, esse tipo de projeto é prático, visto que é menos ambicioso que o projeto de desacopladores dinâmicos.
- 3) Desacoplamento parcial: Consiste na eliminação das interações, dinâmicas ou de regime permanente, focalizada nas malhas que se apresentam de forma mais crítica, mostrando interações muito fortes.

Devido a existência de interação entre as malhas e sendo, essa interação, responsável por dificultar a aplicação das técnicas de controle convencionais. É utilizado técnicas de desacoplamento para compensar o efeito indireto dessas interações. Tham (1999) a técnica de desacoplamento mais aplicada, para a compensação das interações, é a de desacoplamento de regime permanente.

Considerando um sistema TITO (*Two inputs and Two Outputs*) representado a Figura 5. Sendo a matriz de desacoplamento $D(s)$ (equação 43), nos seus termos d_{11} , d_{12} , d_{21} , d_{22} . A matriz de elementos de controle $C(s)$ (equação 44), nos termos c_1 , c_2 . E a matriz de transferência $G(s)$ (equação 45), nos seus termos: g_{11} , g_{12} , g_{21} , g_{22} . Tem-se que a matriz $D(s)$ deve ser projetada de forma que a multiplicação, de acordo com a equação (46), resulte na diagonalização da matriz de transferência na forma da equação 47.

$$D(s) = \begin{pmatrix} d_{11} & d_{12} \\ d_{21} & d_{22} \end{pmatrix} \quad (43)$$

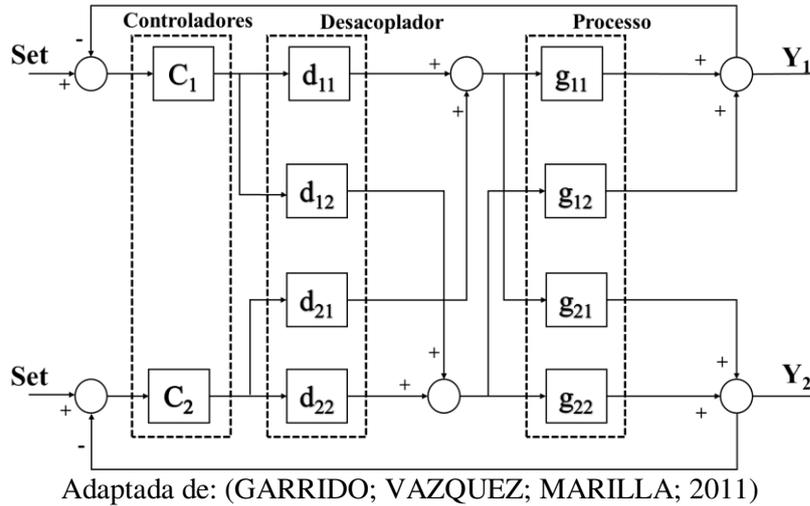
$$C(s) = \begin{pmatrix} c_{11} & 0 \\ 0 & c_{22} \end{pmatrix} \quad (44)$$

$$G(s) = \begin{pmatrix} g_{11} & g_{12} \\ g_{21} & g_{22} \end{pmatrix} \quad (45)$$

$$Q(s) = G(s).D(s) \quad (46)$$

$$Q(s) = \begin{pmatrix} q_{11} & 0 \\ 0 & q_{22} \end{pmatrix} \quad (47)$$

Figura 5 - Estrutura de um desacoplador para o sistema TITO.



De forma geral, as técnicas de desacoplamento convencionais são classificadas em três tipos diferentes: desacoplador ideal; desacoplador simplificado e desacoplador invertido. (GaGnon; Pomerleau; Desbiens, 1998).

4.9.1. Desacoplador ideal

Esse Tipo de desacoplados foi proposto por (LUYBEN, 1970). Tendo como maior “facilidade” permitir que os elementos de controle c_{11} e c_{22} sejam sintonizados de acordo com os elementos atribuído à matriz aparente do processo $Q(s)$. Substituindo as equações (43) e (45) na equação (46). A forma ideal para o desacoplador é definida na forma da equação (48):

$$D(s) = G(s)^{-1}Q(s) = \begin{pmatrix} g_{22}q_{11} & g_{12}q_{22} \\ -g_{21}q_{11} & g_{11}q_{22} \end{pmatrix} \quad (48)$$

4.9.2. Desacoplador Simplificado

Esse segundo tipo de metodologia de desacoplamento foi proposto por (LUYBEN, 1970), sendo vastamente utilizado na literatura, tendo como maior vantagem a simplicidade dos elementos envolvidos. O desacoplador é descrito na forma:

$$D(s) = \begin{pmatrix} 1 & \frac{g_{12}}{g_{11}} \\ -\frac{g_{21}}{g_{22}} & 1 \end{pmatrix} \quad (49)$$

Resultando na seguinte matriz aparente de transferência $Q(s)$:

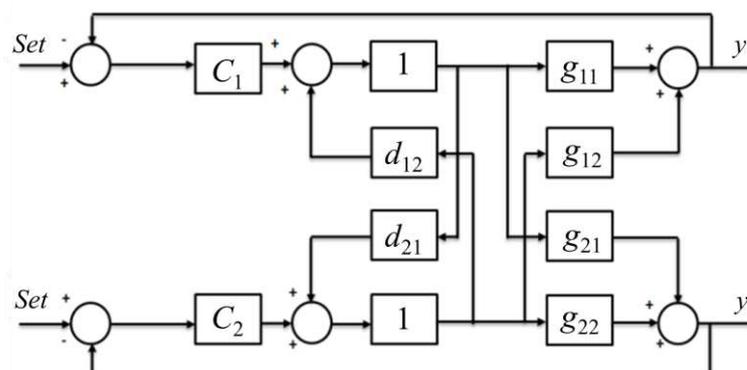
$$Q(s) = G(s).D(s) = \begin{pmatrix} g_{11} - \frac{g_{12}g_{21}}{g_{22}} & 0 \\ 0 & g_{22} - \frac{g_{12}g_{21}}{g_{11}} \end{pmatrix} \quad (50)$$

Esse tipo de desacoplador torna fácil o projeto da matriz de desacoplamento, entretanto, como os elementos de $Q(s)$ são somas de funções de transferência, a sintonia dos controladores pode se tornar mais difícil.

4.9.3. Desacoplador invertido

Desenvolvido como uma alternativa para evitar a utilização da complexa matriz $Q(s)$, estimada na implementação do desacoplador do tipo simplificado, a seguinte estrutura (Figura 6) foi proposta por (SHINSKEY, 1988) na disposição dos elementos do desacoplador.

Figura 6 – Estrutura do desacoplador invertido.



Adaptada de: (GARRIDO, VAZQUEZ e MARILLA; 2011)

Com o surgimento desta estrutura, Wade, (1997) desenvolveu uma nova estratégia que apresenta as mesmas funções de transferência da matriz $D(s)$ presente no desacoplador simplificado e uma matriz aparente do sistema mais simples (desacoplador ideal). Forma do desacoplador:

$$D(s)^{-1} = Q(s)^{-1}G(s) = \begin{pmatrix} 1 & \frac{g_{12}}{g_{11}} \\ -\frac{g_{21}}{g_{22}} & 1 \end{pmatrix} = \begin{pmatrix} \frac{g_{11}}{q_{11}} & -\frac{g_{12}}{q_{11}} \\ \frac{g_{21}}{q_{22}} & \frac{g_{22}}{q_{11}} \end{pmatrix} \quad (51)$$

Para $q_{11} = g_{11}$ e $q_{22} = g_{22}$

$$Q(s)^{-1}G(s) = \begin{pmatrix} 1 & \frac{g_{12}}{g_{11}} \\ -\frac{g_{21}}{g_{22}} & 1 \end{pmatrix} \quad (52)$$

Explicado os conceitos básicos da teoria de desacoplamento, bem como a classificação, quando a forma de determinar as matrizes de desacoplamento. Foi proposto, nesse trabalho a utilização da metodologia ICA, com modificação no processo de branqueamento, como técnica de desacoplamento de sistemas multivariados. Essa técnica foi nomeada de MOD-ICA

5. METODOLOGIA

Apresentada toda a teoria acerca do tema estudado, bem como as modificações proposta pelo os autores, foi realizado um conjunto de estudos de casos para avaliar, de forma prática, a utilização da metodologia ICA junto com as melhorias propostas nesse trabalho. O primeiro estudo foi construído em plataforma *Matlab*® tendo, como objetivo testar a eficiência da correção proposta em comparação com outras técnicas clássicas de análise de componentes independentes, utilizando um sistema com mistura artificial, constituído por três sinais misturados através de uma matriz A randômica. Já o segundo estudo, teve como objetivo mostrar a aplicação, da técnica modificada, no desacoplamento de sistemas multivariados utilizando como processo a planta de obtenção de etanol anidro, via destilação extrativa.

5.1. Sistema com mistura artificial

Nesse primeiro estudo de caso, foram escolhidos 3 sinais ruidosos: Seno duplo; onda dupla e onda periódica, com um número de 1000 amostras para cada sinal. Esses sinais foram misturado por uma matriz randômica de ordem 3, para que fosse simulado a mistura que ocorre nos casos reais. As Equações 5.1, 5.2 e 5.3 mostram os três sinais originais propostos para esse estudo de caso.

$$\text{Seno duplo} \quad s_1 = 0.75 * \sin(w * 12) + 0.1 * \text{randn}(1, N) \quad (5.1)$$

$$\text{Onda Dupla} \quad s_2 = \text{sawtooth}(w * 5, 0.5) + 0.1 * \text{randn}(1, N) \quad (5.2)$$

$$\text{Onda periódica} \quad s_3 = \text{pulstran}((0:999), (0:5)' * 180, \text{kaiser}(100,3)) + 0.07 * \text{randn}(1, N) \quad (5.3)$$

onde N representa o número de pontos, w o vetor de frequência e t um vetor de tamanho N .

Após a mistura artificial, dos sinais originais, e no intuito de testar a eficiência de estimação dos modelos de análise de componentes Independentes e verificar o comportamento da correção proposta, foram utilizados os seguintes métodos de estimação:

- Algoritmo ICA por PCA;
- (Algoritmo ICA por PCA com correção proposta) ou (MOD-ICA);
- Algoritmo JADE;
- Algoritmo *FastICA*;

Para melhor exemplificar a diferença entre os valores estimados, em comparação aos valores de referência, foi determinado o erro de estimação de acordo com a Equação 5.4.

$$Erro_i = (S_i - \hat{S}_i) \quad (5.4)$$

onde S é o valor de referência, enquanto \hat{S} é o valor estimado pelos os algoritmos de Análise de Componentes Independentes escolhidos previamente.

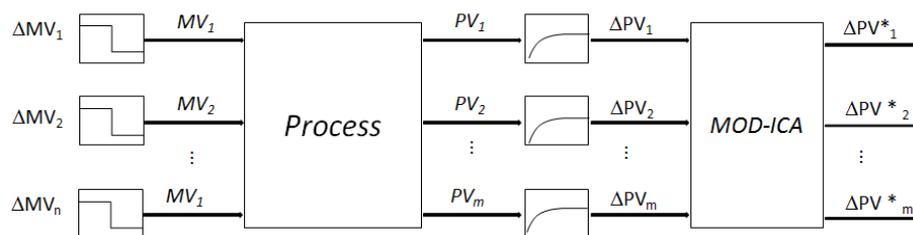
5.2. Aplicação da Técnica de desacoplamento

A técnica MOD-ICA, proposta nesse estudo, foi aplicada no processo de obtenção do etanol anidro, via destilação extrativa, em plataforma *Aspen®*, como técnica para redução do grau de acoplamento do sistema de controle.

Informação sobre a dinâmica do processo foram coletadas utilizando-se de uma variação degrau nas variáveis manipuladas (ΔMV_i). Os ganhos das variáveis de saída (ΔPV_i) foram utilizadas no MOD-ICA, gerando assim os ganhos processados (ΔPV^*_i), como mostra o diagrama da Figura 7. A matriz de ganho, considerando ΔPV^* foi gerada para aplicação da técnica SVD para determinação dos pares para o sistema de controle assim como o condicionamento para verificação indireta do grau de acoplamento do sistema.

Foram utilizadas as informações obtidas através do cálculo do número condicional (NC) e da matriz geral de ganhos relativos (RGA – geral) para verificação do grau de acoplamento do sistema.

Figura 7– Diagrama das etapas de aplicação do MOD-ICA.



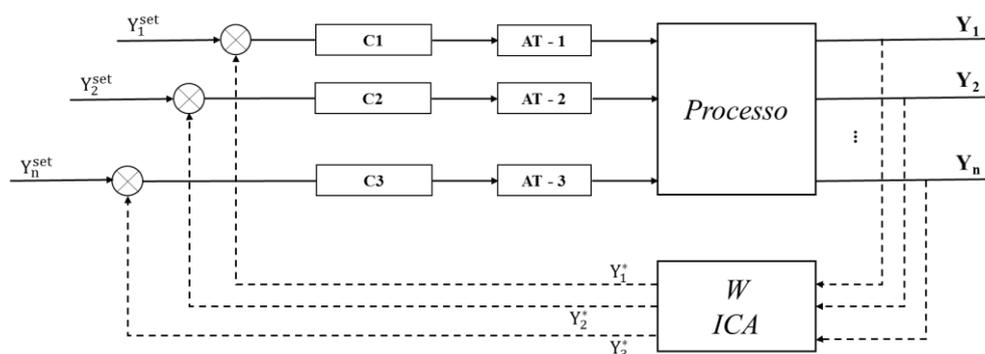
Fonte: Própria

A Figura 7 resume a metodologia aplicada, nesse segundo estudo de caso, para o levantamento dos melhores pares PV-MV das malhas de controle para o processo escolhido. Como critério de avaliação, foi realizada a comparação entre: A técnica SVD, sem a aplicação da metodologia de desacoplamento, e a técnica SVD, com a aplicação do desacoplamento pela a técnica MOD-ICA, proposta nesse trabalho. Utilizando como critérios: o número condicional (NC) e as informações obtidas através do cálculo da matriz geral de ganhos relativos (RGA – geral).

Determinados os emparelhamentos entre os pares PV-MV, utilizando a técnica SVD, com a aplicação do desacoplamento proposto, determinando assim, as malhas de controle para o processo de obtenção do etanol anidro. Foi realizado a implementação do sistema de controle obtido na plataforma Aspen Dynamics®, com o objetivo de testar a real eficiência dessas malhas propostas.

Entretanto, visto que os pares foram determinados através de uma transformação, dos valores dos ganhos de processo (ΔPV^*_i), a aplicação, desse sistema de controle, diretamente no processo de obtenção de etanol anidro, poderia trazer instabilidades para a planta de processo. Diante disto, foi necessário o desenvolvimento da metodologia MOD-ICA de maneira a modificar, em tempo real, os valores das variáveis controladas (PV), levando a interpretação, do novo padrão obtido pelo o MOD-ICA para o sistema de controle, conseqüentemente, acarretando na variação correta da variável manipulada (MV). A Figura 8 traz o diagrama exemplificado da aplicação de controle utilizando a metodologia MOD-ICA.

Figura 8 – Diagrama das etapas de aplicação do MOD-ICA.



Fonte: Própria

5.2.1. Processo de obtenção de etanol anidro

O modelo da planta de obtenção do etanol anidro, via destilação extrativa, foi implementado na plataforma *Aspen® Dynamics* e está apresentada na Figura 9. Para representação do processo foram utilizados os modelos RADFRAC, sendo o mais indicado como representação rigorosa das colunas extrativas e de recuperação de solvente. A coluna extrativa C101 possui 23 estágios de equilíbrio e a coluna de recuperação de solvente C102 apresenta 9 estágios, de acordo com o modelo proposto por Ramos (2016).

Foi utilizado um *Design Specification* para assegurar a composição de solvente no prato de alimentação, conforme metodologia proposta por Figueiredo (2014). A vazão de *make-up*

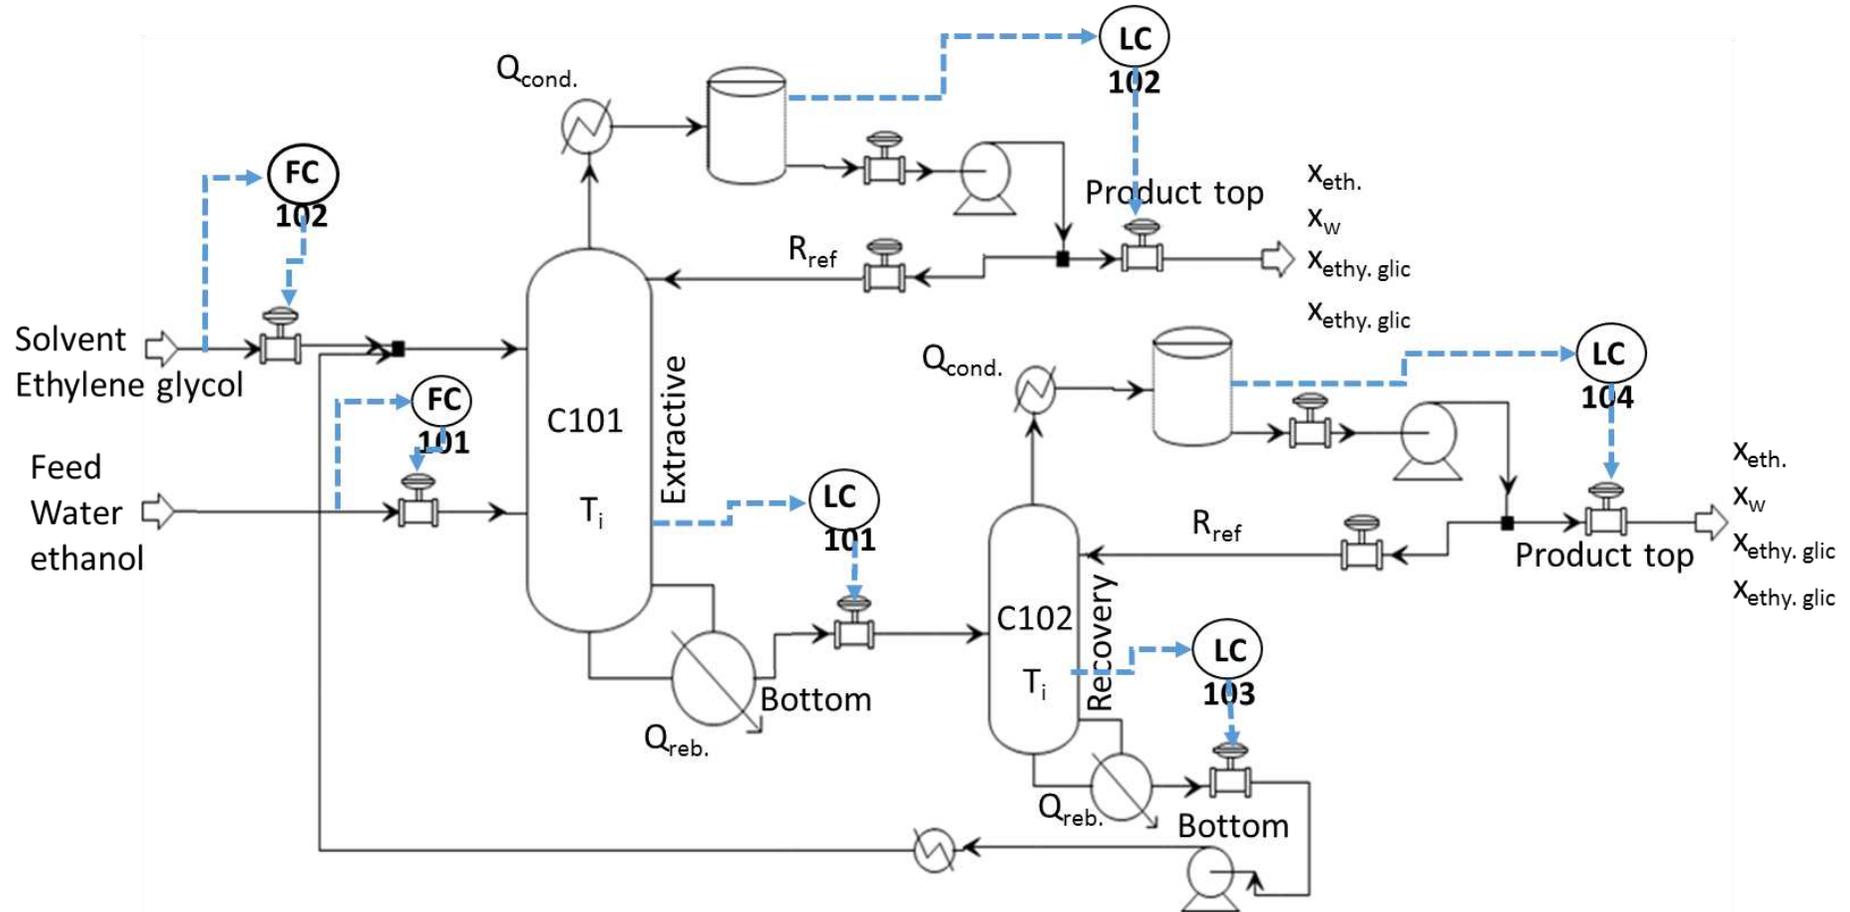
de solvente foi calculada utilizando o *Flowsheet Option: Calculator*, assegurando a reposição do solvente perdido no processo.

Os tanques de refluxo e os vasos *sump* das colunas foram dimensionados considerando o tempo de residência igual a 5 minutos no estado estacionário, conforme o que foi realizado por Coker (2007). Nessa simulação, foram inseridas válvulas entre os equipamentos bem como nas correntes de entrada e saída, como medidas para permitir a simulação no estado dinâmico bem como o sentido do fluxo.

Já na simulação dinâmica, houve a necessidade de inserir controladores de fluxo de alimentação e de níveis. Os controladores de fluxo foram postos para evitar que o erro de convergência numérica não afete a vazão de alimentação da planta. Os controladores de níveis tiveram como objetivo, evitar o efeito integrador apresentado quando a planta foi submetida aos distúrbios do tipo degrau. A Figura 9 apresenta a planta simulada no processo dinâmico, com a implementação dos controles de Fluxo e controle de níveis, necessários para a aplicação da técnica SVD, juntamente com a metodologia MOD-ICA.

A partir do modelo dinâmico da planta em questão, foram levantadas as possíveis 6 variáveis manipuladas (MVs), bem como as possíveis 38 variáveis controladas (PVs). As variáveis manipuladas foram: carga térmica dos condensadores, dos reboilers, e razão de refluxo de ambas as colunas. As variáveis de processo foram: fração molar de etanol, fração molar de etileno-glicol no destilada e fração molar de água no destilado da “C101”, fração molar de etanol, fração molar de etileno-glicol e fração molar de água no destilado da “C102”, e por fim o perfil de temperatura em ambas as colunas.

Figura 9 – Esquema de desacoplamento proposto.



Fonte: Própria

6. RESULTADOS

As técnicas clássicas de separação cega de sinais foram aplicadas a um sistema artificial de três sinais implementadas na plataforma *Matlab*®. Utilizando a modificação proposta nesse trabalho, o método ICA por PCA foi avaliado com o mesmo sistema artificial de sinais. Os tópicos seguintes tratam da apresentação da avaliação das técnicas clássica e com a modificação proposta.

6.1. Aplicação das técnicas clássicas

No primeiro estudo de caso proposto, foi gerado os gráficos dos sinais de referência, com a posterior mistura desses sinais, a partir de uma matriz randômica A (Matriz de mistura). Para melhor visualização dos gráficos, o número de pontos foi reduzido pela metade. As Figuras 10 e 11 trazem o comportamento dos sinais de referência e os sinais misturados pela matriz A , mostrada na Equação 6.1.

Figura 10- Sinais originais: (a) – Seno Duplo; (b) – Onda duplo; (c) – Onda Periódica;

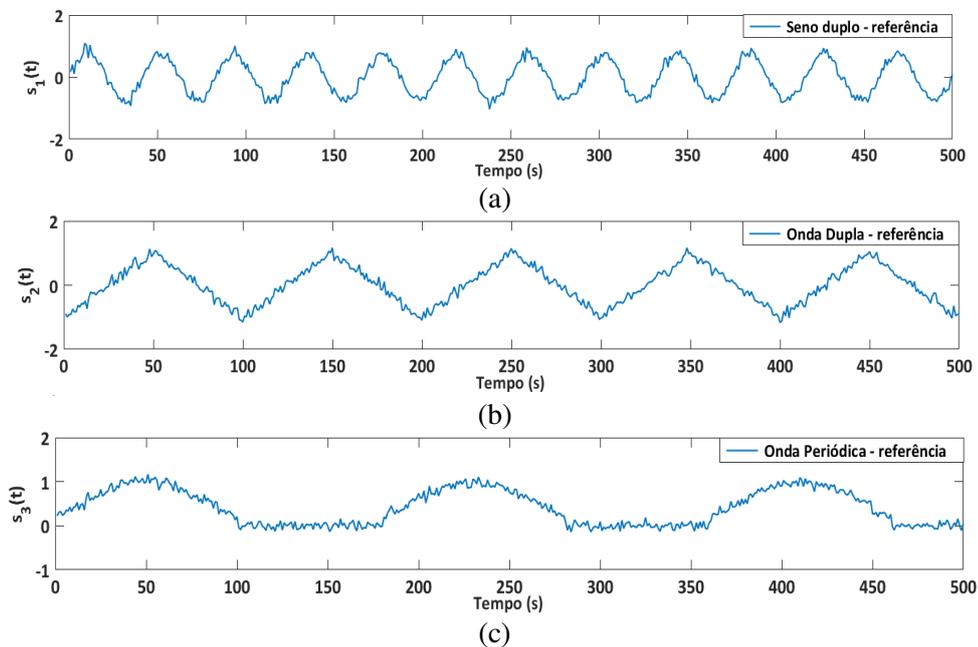
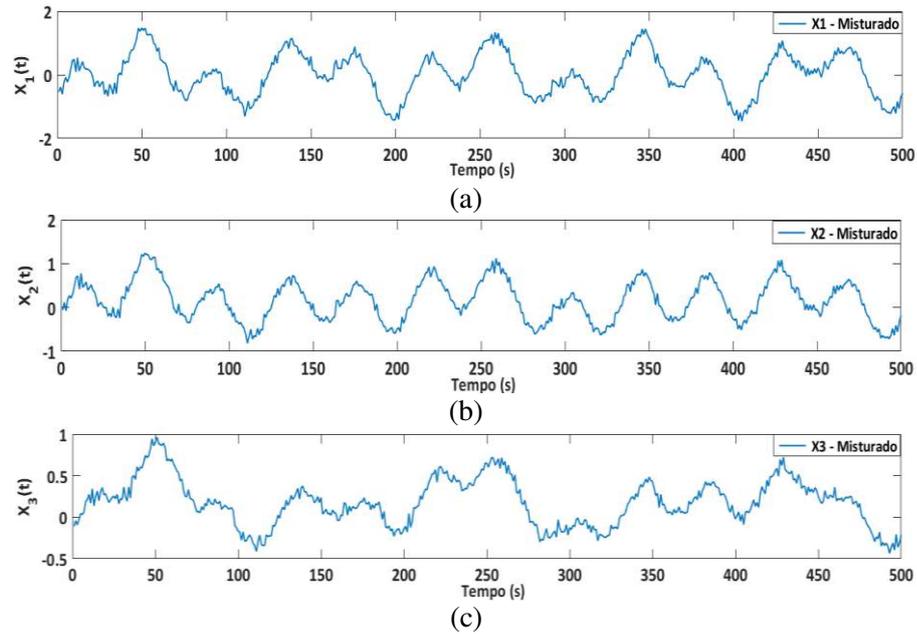


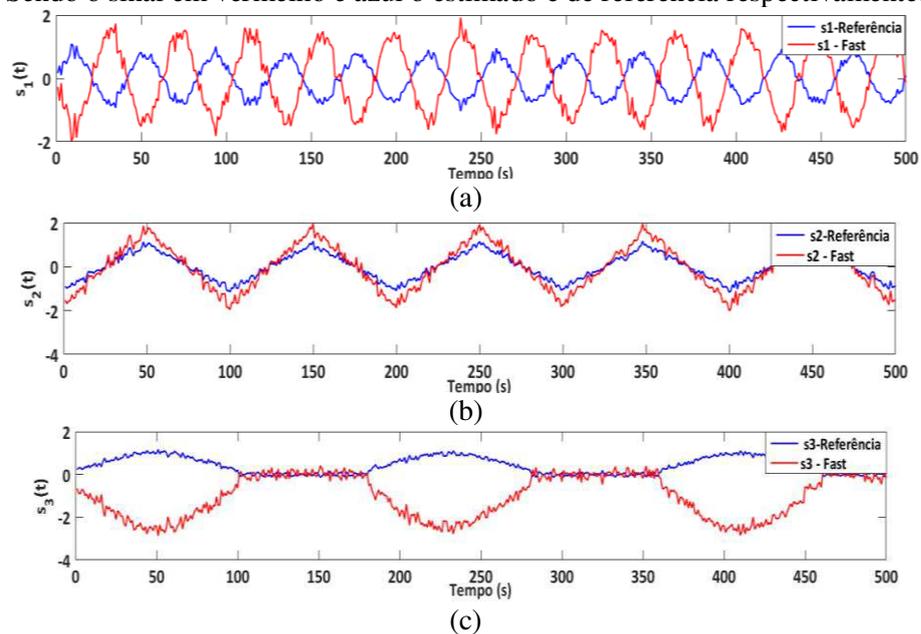
Figura 11- Sinais Misturados pela a matriz A.



$$A = \begin{pmatrix} 0.8842 & 0.7598 & 0.0061 \\ 0.7006 & 0.2909 & 0.3747 \\ 0.2419 & 0.2774 & 0.4369 \end{pmatrix} \quad (6.1)$$

Realizado a mistura dos sinais escolhidos, seguiu-se para o processo de separação a partir dos vetores de sinais estimados. Nesse estudo de caso, tem-se que o número de fontes e de sensores são iguais, a Figura 12 mostra os sinais estimados pelo a metodologia *FastICA* proposto por Hyvarinen (1999b).

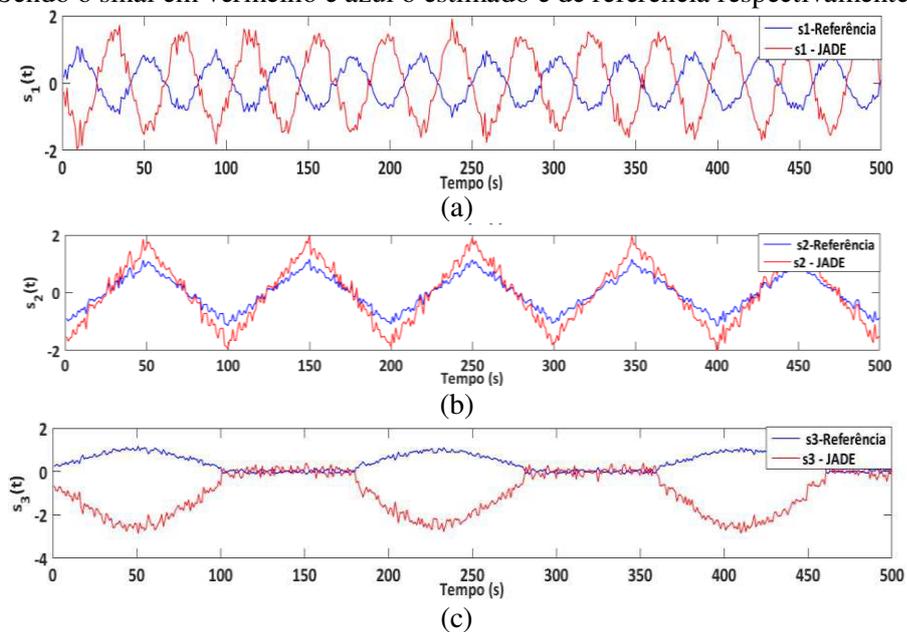
Figura 12- Sinais estimados pelo o FastICA: (a) – Seno duplo; (b) – onda dupla; (c) – Onda periódica. Sendo o sinal em vermelho e azul o estimado e de referência respectivamente.



Analisando a Figura 6, verifica-se a diferença entre a estimação e a referência dos sinais quando se utiliza a técnica *FastICA* para a separação dos sinais. Evidenciando assim, a presença de erros de amplitudes, para todos os gráficos da Figura 12 e erros de fase na Figura 12(a) e 12(c).

Feitas as análises com a ferramenta *FastICA*, foi realizado a estimação, utilizando a técnica *JADE* proposto por Cardoso (1993). A Figura 13 traz os sinais estimados por esse método de separação cega.

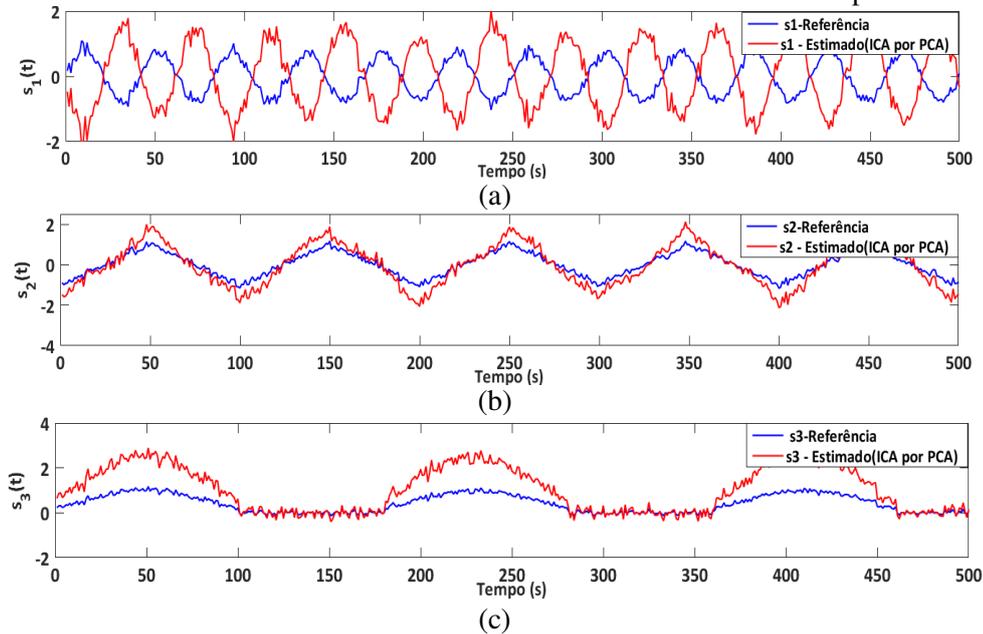
Figura 13 - Sinais estimados pelo o *JADE*: (a) – Seno duplo; (b) – onda dupla; (c) – Onda periódica. Sendo o sinal em vermelho e azul o estimado e de referência respectivamente.



Analisando os resultados de estimação do método *JADE* na Figura 13 e comparando-os com os resultados da estimação do método *FastICA* da Figura 12, observa-se que a estimativa obtida pelos os dois métodos foram semelhantes, apresentando os mesmos erros de amplitude e inversão de fase.

O algoritmo ICA por PCA proposto por Kun e Chan (2006) foi aplicado aos dados de mistura proposto nesse estudo de caso. A Figura 14 traz o sinal estimado por esse algoritmo.

Figura 14 - Sinais estimados pelo ICA por PCA: (a) – Seno duplo; (b) – onda dupla; (c) – Onda periódica. Sendo o sinal em vermelho e azul o estimado e de referência respectivamente.



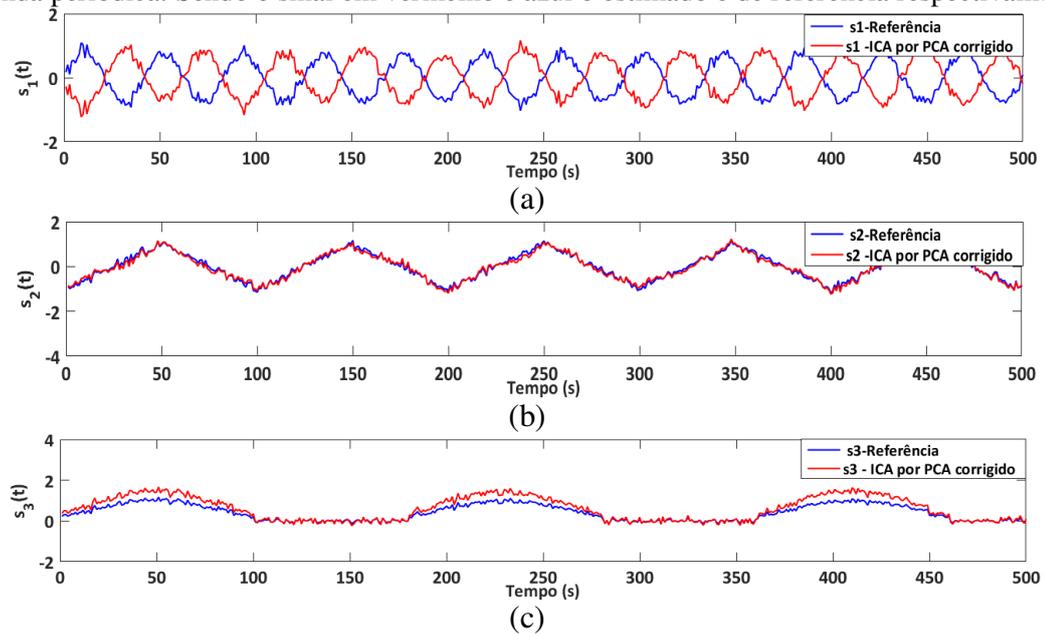
Analisando a Figura 14, observa-se que o método ICA por PCA apresenta uma melhor estimativa quanto a fase dos sinais, quando comparado com os dados obtidos nas estimativas dos algoritmos *FastICA* e *JADE*. Tem-se que o método ICA por PCA conseguiu estimar duas das fases corretas dos sinais proposto, enquanto que nas outras ferramentas houve a inversão de dois sinais.

6.2. Aplicação da modificação proposta

Como definido na Equação 33, no intuito de avaliar correção da etapa de branqueamento, a ponderação proposta foi aplicada ao algoritmo *ICA* por *PCA*. A técnica *ICA* por *PCA* modificada foi comparada com as técnicas clássica *FastICA*, *JADE* e *ICA-PCA* quanto ao desempenho da separação dos sinais do sistema artificial. A Figura 15 apresenta o resultado da separação do sistema artificial proposto.

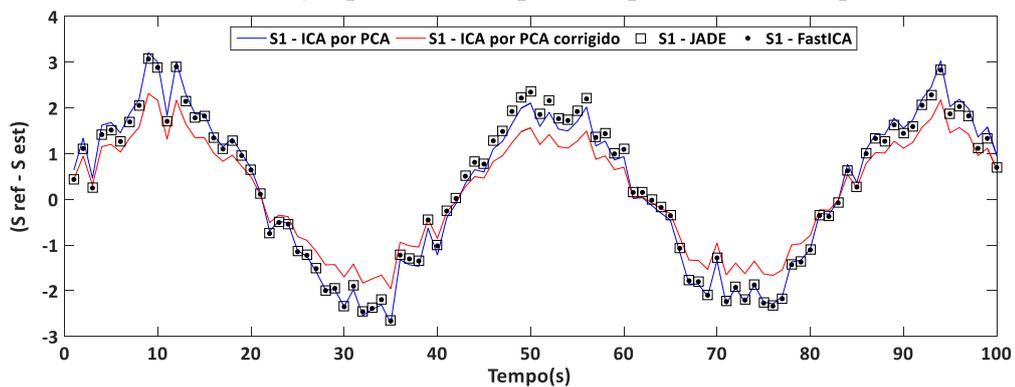
Analisando a Figura 15 e comparando-a com as Figuras 12, 13 e 14, que trazem as estimativas dos métodos *FastICA*, *JADE* e *ICA* por *PCA* respectivamente, observa-se uma redução significativa no erro de amplitude do sinal estimado. Mesmo nos casos onde houve a inversão das fases, a amplitude do sinal estimado está próxima do valor de referência.

Figura 15 - Sinais estimados pelo ICA por PCA com correção: (a) – Seno duplo; (b) – onda dupla; (c) – Onda periódica. Sendo o sinal em vermelho e azul o estimado e de referência respectivamente.



Para verificar as diferenças de estimação dos sinais propostos de forma quantitativa, foi calculado o desvio entre os sinais: estimados e de referência, de acordo com a equação 35. O comportamento desses desvios está mostrado nas Figuras 16, 17 e 18 para os sinais: seno duplo, onda duplo e onda periódica respectivamente.

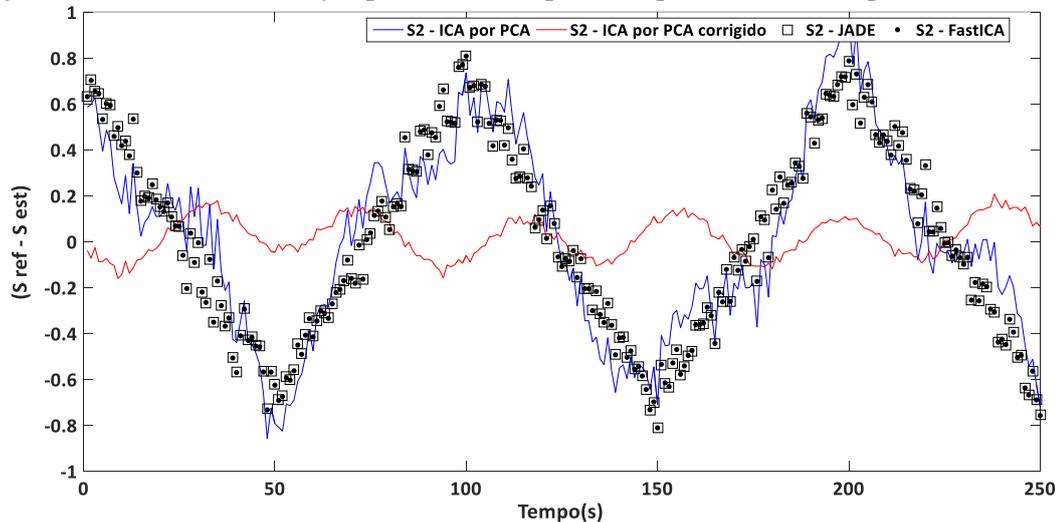
Figura 16 - Desvio de estimação para o seno duplo: Comparativo entre as quatro estimativas.



O comportamento do desvio para o sinal: “Seno duplo”, de todos os algoritmos utilizados, mostrado na Figura 16, evidencia a melhoria provocada pela correção proposta nesse trabalho. Observa-se também que os valores dos desvios apresentam valores aproximados em decorrência do fato de que os valores estimados, para esse sinal, foram semelhantes em magnitude, comprovados pelas Figuras 12(a), 13(a), 14(a) e 15(a). Porém, mesmo que seus

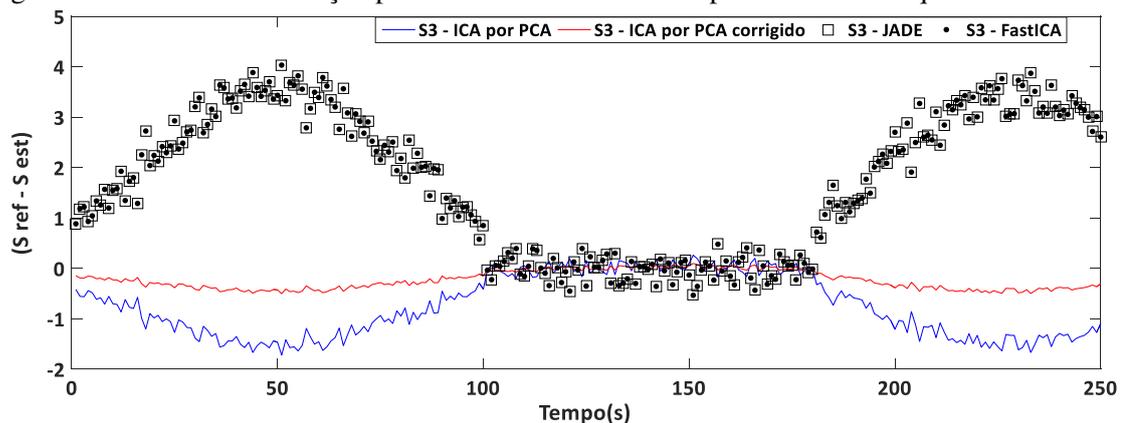
valores estejam próximos, fica evidente a melhoria decorrente da correção proposta nesse trabalho.

Figura 17 - Desvio de estimação para a Onda duplo: Comparativo entre as quatro estimativas.



O comportamento mostrado na Figura 17 destaca a melhoria provocada pela modificação proposta ao método ICA por PCA (Figura 15(b)), em relação aos algoritmos FastICA (Figura 12(b)) e JADE (Figura 13(b)), bem como em relação a própria estimação ICA por PCA (Figura 14(b)). A Figura 18 também mostra o comportamento já esperado com desvios, sendo mais altos para as estimativas dos algoritmos FastICA e JADE e menores para o método ICA por PCA clássico e com a correção proposta.

Figura 18 - Desvio de estimação para a Onda Periódica: Comparativo entre as quatro estimativas.



Posteriormente às análises dos desvios absolutos, entre os sinais separados em comparação os sinais de referência, foram calculados na forma de índice de desempenho para a separação pelo os algoritmos ICA. O índice escolhido para a quantificação do desempenho foi o IAE (*Integral of the Absolute Magnitude of the Error*). Na forma geral representado pela

a equação 6.2. A Tabela 1 traz os valores calculados para ambos os métodos de separação desses índices.

$$IAE = \int_0^T |e(t)| dt \quad (6.2)$$

Tabela 1 - Índice de desempenho

	<i>FastICA</i>	<i>JADE</i>	ICA por PCA	ICA por PCA corrigido
Seno Duplo	0,6960	0,6953	0,9608	0,6652
Onda Dupla	0,7581	0,7566	0,7215	0,0650
Onda Periódica	2,6066	2,6080	1,093	0,3074

De acordo com a Tabela 1, fica evidente que a modificação proposta, aplicada ao algoritmo ICA por PCA, possibilitou diminuir o erro de estimação, mesmo quando os sinais “decorreram” de uma inversão do sinal de referência, o que foi observado na estimativa dos sinais seno duplo e onda periódica. Para o sinal onda dupla, onde todos os algoritmos conseguiram estimar o sinal com a mesma fase do sinal original, fica evidente a redução do erro, após a aplicação da correção ao processo de branqueamento.

6.3. Emparelhamento pela a técnica SVD utilizando a metodologia MOD-ICA

Utilizando o modelo do processo, em ambiente *Aspen Dynamics®*, foram aplicados distúrbios nas 6 MV's ($Q_{cond,101}$, $Q_{cod,102}$, $Q_{reb,101}$, $Q_{reb,102}$, $R_{ref,101}$, $R_{ref,102}$) escolhidos numa faixa em torno de 0,01% à 0,5%. As variações das 38 PV's ($T_{i,101}$, $T_{i,102}$, $X_{itop,101}$, $X_{itop,102}$) foram obtidas e utilizadas para o cálculo da matriz de ganho estático, de acordo com a Equação (6.3). A matriz de ganho estático, foi aplicada no método SVD, na sua forma clássica e utilizando a técnica MOD-ICA.

$$K = \frac{\Delta PV_i}{\Delta MV_i} \quad (6.3)$$

A partir da decomposição da matriz de ganho, utilizando o método SVD clássico, foram obtidos os emparelhamentos e o cálculo do número condicional apresentado na Tabela 2. O mesmo procedimento de aplicação da matriz de ganho, a partir do método MOD-ICA, estão apresentados na mesma Tabela 2.

Tabela 2 - Emparelhamento proposto pelo SVD Clássica e SVD com a metodologia MOD-ICA

SVD Clássico			SVD com MOD-ICA		
Variável de processo	Variável manipulada	Número condicional	Variável de processo	Variável manipulada	Número Condicional
$x_{eth., top}$ - C102	$Q_{Reb.}$ - C102	1	$x_{eth., top}$ - C102	$Q_{Reb.}$ - C102	1
T_7 - C102	$Q_{Cond.}$ - C101	140,88	$x_{wat., top}$ - C102	$R_{ref.}$ - C101	36,05
T_{22} - C101	$Q_{Reb.}$ - C101	470,95	T_8 - C102	$Q_{Reb.}$ - C101	75,119
$x_{eth., top}$ - C101	$Q_{cod.}$ - C102	4.360,85	T_7 - C102	$Q_{Cond.}$ - C102	697,67
T_{21} - C101	$R_{ref.}$ - C101	16.960,49	T_{22} - C101	$Q_{Cond.}$ - C101	768,00
T_6 - C102	$R_{ref.}$ - C102	120.686,40	T_{21} - C101	$R_{ref.}$ - C102	875,41

Comparando os dados fornecidos na Tabela 2, observa-se que a aplicação do MOD-ICA, para o desacoplamento, além de determinar um conjunto de emparelhamento diferentes, quando aplicado a SVD convencional, reduziu de forma significativa o número condicionante do sistema. Essa redução no número condicionante, pode ser traduzida por uma maior controlabilidade para o sistema e numa diminuição da incerteza para o modelo do processo. Ainda sobre a redução do número condicionante, tem-se que, essa redução pode ser utilizada como indicador do desacoplamento do sistema.

6.4. Cálculo da Matriz de ganhos relativos

Os emparelhamentos encontrados pelas técnicas SVD clássica e utilizando o a técnica MOD-SVD foram avaliadas, quanto a condição de acoplamento do sistema. As Tabelas 3 e 4 apresentam, respectivamente, a matriz RGA para a SVD clássica e SVD com a MOD-ICA. Os valores calculados pela RGA, para os pares obtidos a partir da SVD com o MOD-ICA, estão em sua maioria dentro da faixa de 0 a 1.

Tabela 3 - RGA para a SVD Clássica

SVD - Clássico	MV4	MV1	MV3	MV2	MV5	MV6
PV4	0,373	3,326	-0,209	-3,535	-0,020	1,066
PV36	2,197	0,695	-1,310	-3,326	-0,473	3,216
PV28	-2,087	-2,171	-0,161	1,613	4,542	-0,737
PV1	-2,035	-0,743	0,638	3,880	-1,739	1,000
PV27	-0,518	0,395	2,533	-0,069	-1,739	0,398
PV34	3,070	-0,502	-0,491	2,436	0,429	-3,943

Tabela 4- RGA para a SVD/MOD - ICA

SVD – ICA	MV4	MV5	MV3	MV2	MV1	MV6
PV4	3.509	-152.534	-1.432	0.148	153.923	-2.619
PV6	-3.468	153.474	1.444	-0.161	-152.962	2.672
PV37	0.099	0.007	0.431	0.465	-0.004	0.003
PV36	0.031	0.001	0.443	0.538	-0.012	-0.001
PV28	0.125	0.052	0.033	0.005	0.004	0.780
PV27	0.705	0.000	0.081	0.005	0.050	0.165

Devido aos valores negativos, pode-se reduzir a estrutura de controle para um sistema 4x4 para a RGA do SVD Clássico, apresentada na Tabela 5. Observa-se que a retirada das malhas 5 e 6 provocou uma melhora nos valores para a RGA do sistema, no entanto, a dificuldade devido ao acoplamento do sistema ainda persiste. O mesmo procedimento de redução dos pares foi realizado, semelhante ao realizado no emparelhamento clássico, sendo retirado do sistema de controle os emparelhamentos: 1 (MV4 - PV4) e 2 (MV5 - PV6), devido ao fato de os mesmos apresentarem valores de ganho relativos muito distantes do valor unitário. A Tabela 5 apresenta os novos valores de ganhos relativos para o novo sistema reduzido.

Tabela 5- RGA para os sistemas 4x4 a partir do SVD Clássica e SVD MOD-ICA

SVD Clássico	MV4	MV1	MV3	MV2	SVD MOD-ICA	MV3	MV2	MV1	MV6
PV4	0,935	3,176	-0,266	-2,84	PV37	0,592	0,3483	0,0609	-0,0019
PV36	4,37	0,4330	-1,80	-2,00	PV36	0,512	0,5950	-0,1050	0,0020
PV28	-2,88	-0,825	3,22	1,482	PV28	-0,008	0,0194	0,2486	0,7405
PV1	-1,42	-1,784	-0,15	4,36	PV27	-0,09	0,037	0,7954	0,2634

Na Tabela 5, para a RGA com o SVD clássico, observa-se que a retirada das malhas de controle, que estavam com maior competição entre si, provocou um ajuste nos valores de ganhos relativos. No entanto, uma redução no grau de acoplamento ainda se faz necessário. Para o sistema de pares obtidos a partir do SVD/MOD-ICA, uma redução significativa no grau de acoplamento foi alcançada, uma vez que os valores obtidos estão próximos a 1 (um) e maiores que 0 (zero). Pode-se destacar também que a análise da RGA do sistema SVD/MOD-ICA indicou a retirada do emparelhamento de controle contendo as frações molares de etanol (PV4) e de etileno-glicol (PV5) na corrente de destilado da C102, evitando assim, a necessidade da utilização de sensores para leitura dessas possíveis variáveis controladas.

6.5. Avaliação dinâmica dos pares de controle propostos

Feitas as avaliações, acerca da correção no processo de branqueamento, comparando com as metodologias clássicas e determinando o emparelhamento das variáveis de controle, através da utilização conjunta das técnicas SVD e MOD-ICA, foi necessário a implementação das malhas de controle projetadas no intuito de comprovar a real utilização das técnicas de análise de componentes independentes para o controle real de processos industriais. A Figura 20 apresenta o fluxograma da planta de obtenção de etanol anidro, via destilação extrativa, construída no simulador dinâmico *Aspen Dynamics*®, com todos os controladores projetados para a adequação das etapas descritas na metodologia desse trabalho.

O processo demonstrado na Figura 20, tem como objetivo elevar a concentração molar de 85 %, no ponto de azeótropo, da solução de etanol, há uma concentração comercial de etanol anidro em torno de 99,5 % molar na corrente de destilado da coluna extrativa (corrente “DEST-01”). Como objetivos secundários, visou-se a importância de assegurar a pureza de água, na corrente “DEST-02”, como forma de evitar a perda do solvente etileno-glicol, garantindo a sua pureza da corrente de base da coluna C102 (coluna de recuperação).

Os controladores de Fluxo de alimentação “FC101” foi projetado para compensar as perdas do solvente, através de uma corrente de “*make up*” (corrente “SOLV”) de forma a manter um fluxo molar da alimentação do solvente etileno-glicol em torno de $107,9 \text{ Kmol.hr}^{-1}$ a uma concentração molar em torno de 99,78 % de etileno-glicol na alimentação da coluna “C101” do fluxograma apresentado na Figura 20. Já o controlador “FC102” tem como função manter o fluxo molar de alimentação no valor de 100 Kmol.hr^{-1} a uma concentração molar de 85 % de Etanol. Para os dois controladores de fluxo foi considerado a utilização do algoritmo de controle do tipo PI (Proporcional – Integral).

Os tanques de refluxo “F101” e “F103” foram projetados para absorver distúrbios do processo, com a finalidade de manter a vazão de refluxo de acordo com o especificado na etapa de projeto. Já os controladores “LC101”, “*Sump's* da C101”, “LC102”, “vaso de refluxo da C101”, “LC103”, “*Sump's* da C102” e “LC104”, “vaso de refluxo da C102” foram implementados, com funções regulatórias para a manutenção dinâmica do sistemas, evitando as ações integradoras provenientes dos distúrbios do processo.

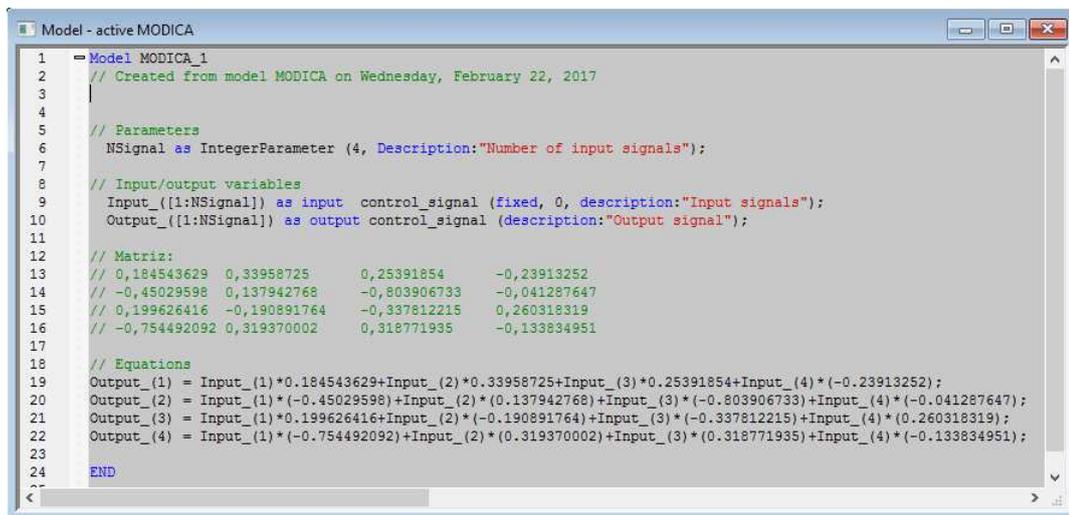
Após a implementação dos controladores de ajustes para o efeito integrador, foram aplicados os emparelhamentos propostos a partir da utilização da técnica SVD com o

desacoplamento pela a técnica MOD-ICA, bem como todos os equipamentos de leitura dos sinais necessários para as avaliações dos pares de controle. Para a leitura das PV's, $T_{8,C102}$, T_7 , $C102$, $T_{22,C101}$ e $T_{21,C101}$ foram utilizados, respectivamente, os Sensores V_1 , V_2 , V_3 e V_4 .

As informações lidas a partir desse sensores foram inseridas no Bloco de nome "MICA1" onde, através da utilização de "Custom Modeling" para a implementação do algoritmo referente à aplicação da técnica de análise de componentes Independentes, proposta nesse trabalho. Como dito nesse trabalho, acerca da modelagem básica da metodologia ICA, a separação dos dados é realizada a partir da multiplicação dos sinais misturados pela matriz de separação W . Essa matriz, para a aplicação no desacoplamento, foi estimada ainda na etapa de projeto dos possíveis pares de controle (Aplicação da SVD com desacoplamento pela a MOD-ICA), sendo implementada na plataforma *Aspen Dynamics*®, através do "Custom Modeling" "MICA1". A matriz de separação está representada pela Equação (6.4). A implementação da matriz W no simulador *Aspen Dynamics*® é apresentada na Figura 19.

$$W = \begin{pmatrix} 0,184543629 & 0,33958725 & 0,25391854 & -0,23913252 \\ -0,45029598 & 0,137942768 & -0,803906733 & -0,041287647 \\ 0,199626416 & -0,190891764 & -0,337812215 & 0,260318319 \\ -0,754492092 & 0,319370002 & 0,318771935 & -0,133834951 \end{pmatrix} \quad (6.4)$$

Figura 19 - Implementação da matriz de separação.



```

1  Model - active MODICA
2  == Model MODICA_1
3  // Created from model MODICA on Wednesday, February 22, 2017
4
5  // Parameters
6  NSignal as IntegerParameter (4, Description:"Number of input signals");
7
8  // Input/output variables
9  Input_{[1:NSignal]} as input control_signal (fixed, 0, description:"Input signals");
10 Output_{[1:NSignal]} as output control_signal (description:"Output signal");
11
12 // Matriz:
13 // 0,184543629 0,33958725 0,25391854 -0,23913252
14 // -0,45029598 0,137942768 -0,803906733 -0,041287647
15 // 0,199626416 -0,190891764 -0,337812215 0,260318319
16 // -0,754492092 0,319370002 0,318771935 -0,133834951
17
18 // Equations
19 Output_(1) = Input_(1)*0.184543629+Input_(2)*0.33958725+Input_(3)*0.25391854+Input_(4)*(-0.23913252);
20 Output_(2) = Input_(1)*(-0.45029598)+Input_(2)*(0.137942768)+Input_(3)*(-0.803906733)+Input_(4)*(-0.041287647);
21 Output_(3) = Input_(1)*0.199626416+Input_(2)*(-0.190891764)+Input_(3)*(-0.337812215)+Input_(4)*(0.260318319);
22 Output_(4) = Input_(1)*(-0.754492092)+Input_(2)*(0.319370002)+Input_(3)*(0.318771935)+Input_(4)*(-0.133834951);
23
24 END

```

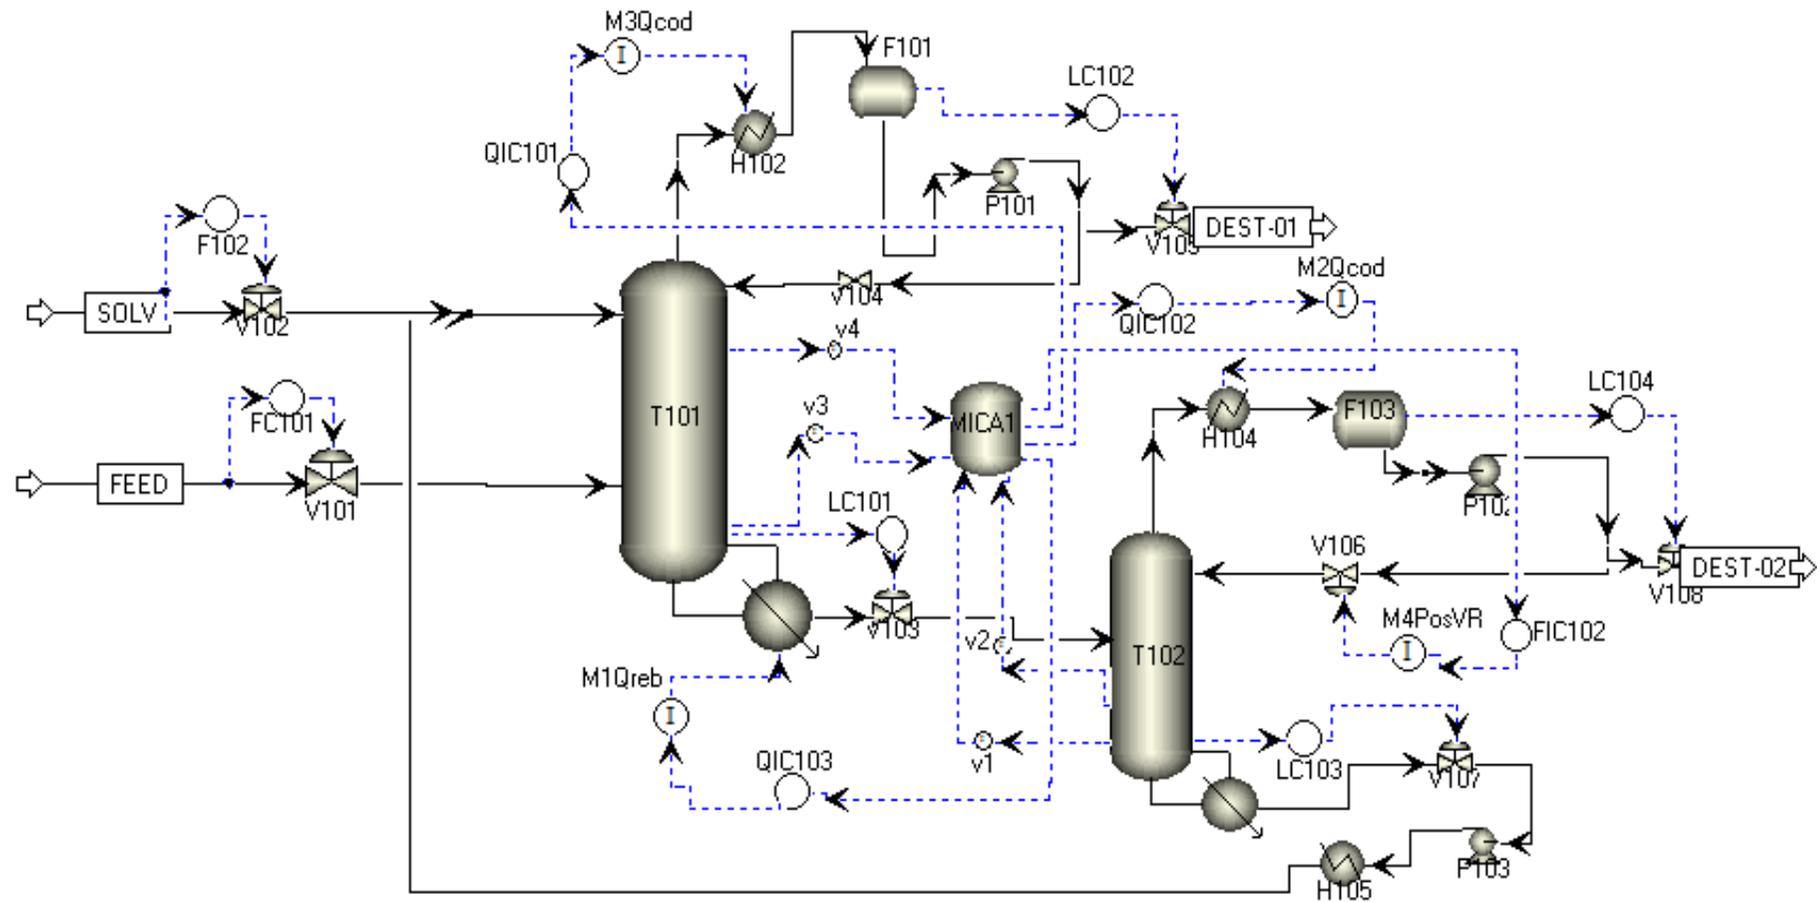
Os novos padrões, obtidos após a aplicação da metodologia MOD-ICA, foram utilizados, respectivamente, como entradas para os controladores: "QIC103", "QIC102", "QIC101" e "FIC102". A implementação desses controladores seguem a ordem especificada pela análise do número condicional. O controlador "QIC103" tem como função manter a temperatura do estágio 8 da coluna de recuperação "C102", utilizando a carga do *Reboiler* da

coluna de extração “C101”. O controlador “QIC102” possui como variável de processo, a temperatura do estágio 7 da coluna de recuperação, utilizando a carga térmica do condensador, da “C102” como variável manipulada. O controlador “QIC101” foi implementado com o objetivo de manter a temperatura do estágio 22, da coluna de extração (“C101”) manipulando a carga térmica do condensador da coluna “C101”. O controlador “FIC102” utiliza a razão de refluxo da coluna “C102” (posição da válvula “V106”), como variável manipulada, para o controle da temperatura do estágio 21 da coluna extrativa (“C101”). A Tabela 6 mostra as especificações de *Setpoint*, variável manipulada e ação de controle, especificado para os controladores utilizados.

Tabela 6– Especificações de controle

Controlador	<i>Setpoint</i> (°C)	Variável manipulada	Ação de controle
QIC103	$T_{8, C102} \setminus 83,372$	$Q_{\text{Reb}, C101} \setminus 3,932 \text{ MMkcal.hr}^{-1}$	Inversa
QIC102	$T_{7, C102} \setminus -143,819$	$Q_{\text{cond}, C102} \setminus -0,855 \text{ MMkcal.hr}^{-1}$	Inversa
QIC101	$T_{22, C101} \setminus -5,612$	$Q_{\text{cond}, C101} \setminus -3,440 \text{ MMkcal.hr}^{-1}$	Direta
FIC102	$T_{21, C101} \setminus -60,204$	$R_{\text{Ref}} \setminus 50,00 \%$	Inversa

Figura 20 - Fluxograma de produção de entanol anidro simulada em Aspen Dynamics.



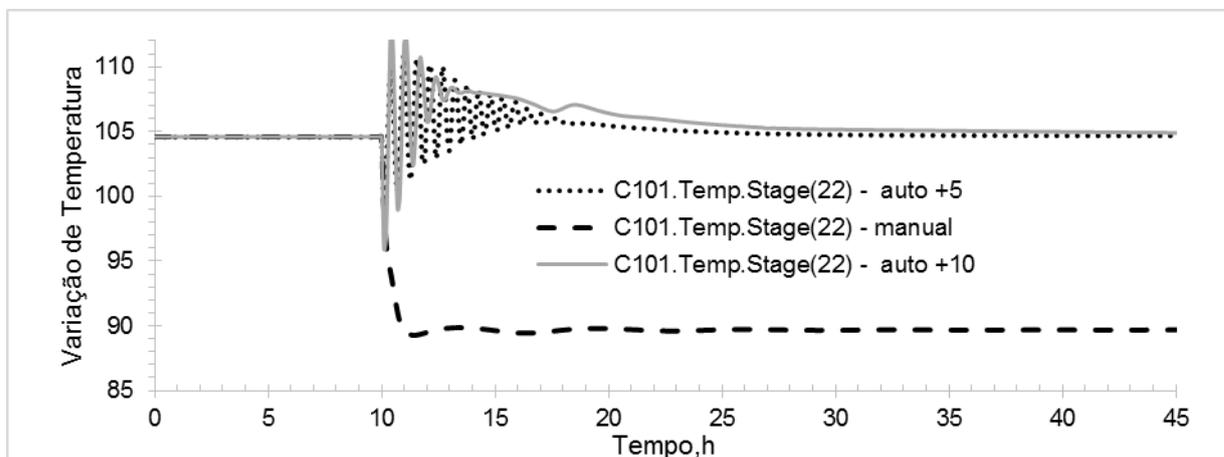
6.5.1. Simulação dinâmica do sistema proposto

Após as etapas: construção do modelo dinâmico, do processo de obtenção de etanol anidro; realização do projeto de emparelhamento, através das técnicas combinadas SVD/MOD-ICA; implementação das malhas de controle determinadas, tem-se como resultados a avaliação do sistema de controle a uma perturbação positiva de 5%, 10 % e perturbação negativa de 1 % no fluxo de alimentação de etanol a 85 %.

As variáveis que escolhidas para serem monitorados são: fração molar de etanol no destilado da “C101”; fração molar de água no destilado da “C102” e fração molar de etileno-glicol na corrente de base da “C102”, além das variáveis de controle selecionadas.

Antes de realizar a comparação, entres os distúrbios planejados anteriormente. Foi construído um gráfico da variação da temperatura do estágio 22, com o distúrbio degrau de 5% e 10 % no fluxo de alimentação de etanol, para os casos onde todos os controladores, projetados pelo o SVD/MOD-ICA, estavam no modo manual e automático. A Figura 21 mostra a variação da temperatura do estágio 8 da coluna “C102” com o tempo.

Figura 21– Variação da Temperatura do estágio 22 da “C102” com o tempo.

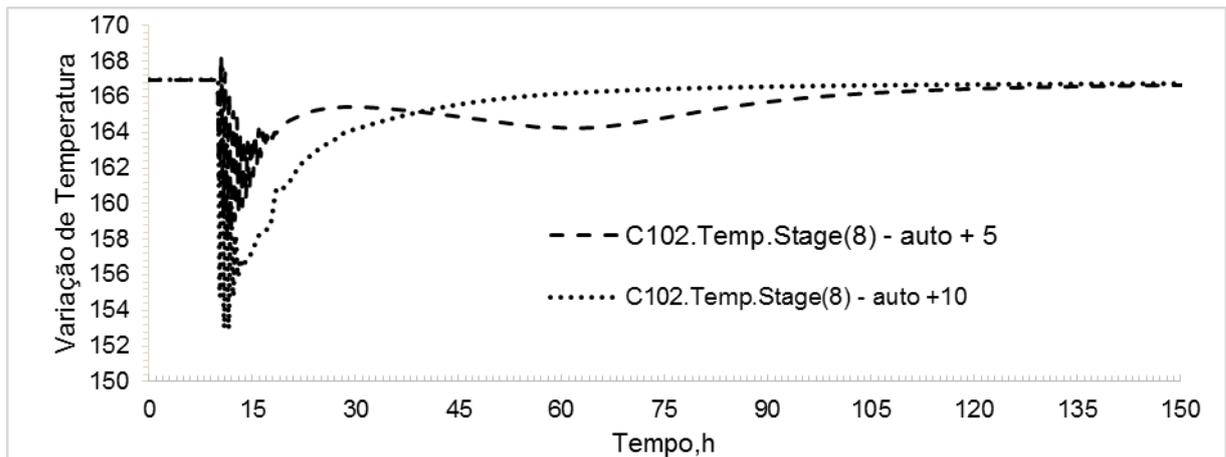


Observa-se que o distúrbio na vazão de alimentação foi aplicado no tempo igual a 10 h. No gráfico da Figura 21 fica evidente a ação de controle no sistema, visto que, a temperatura do estágio 22, no controle manual, estabiliza muito distante do valor inicial de 105 °C em contraste com o comportamento quando os controladores foram ativados.

Dada a importância da ação de controle, para a variação da temperatura, foram plotados os gráficos para as outras variáveis de interesse, comparando agora, as variações para os distúrbios de +5 %, +10 % e -1% com a utilização dos controladores no modo automático.

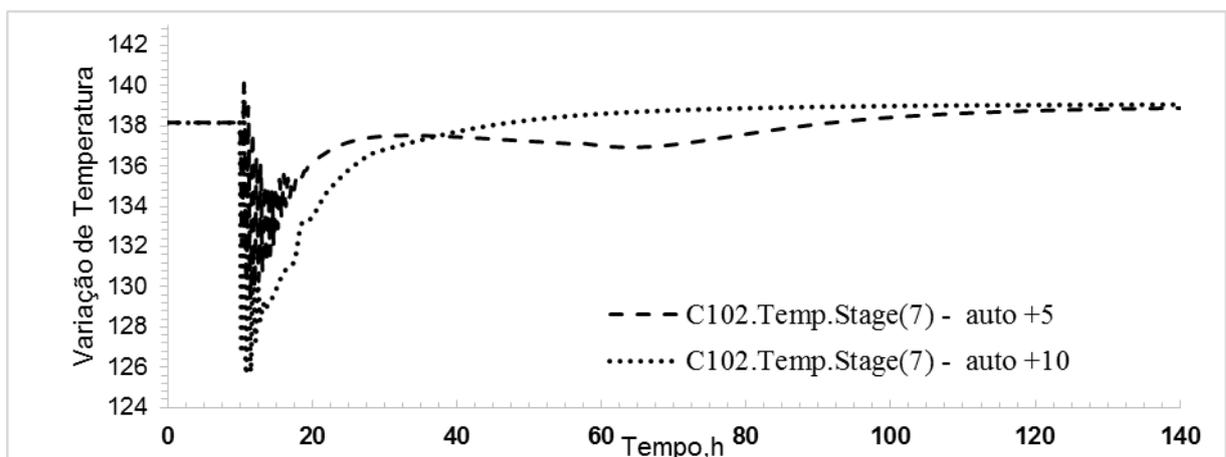
A Figura 22 apresenta o comportamento para a temperatura do estágio 8 da coluna de recuperação de etileno-glicol. Observa-se que o comportamento oscilatório da temperatura, na variação degrau de +5% e +10, após a sua aplicação no tempo de 10 h, foram semelhantes, porém a variação de + 10 alcançou o valor estacionário mais rapidamente.

Figura 22 – Variação da Temperatura do estágio 8 da “C102” com o tempo.



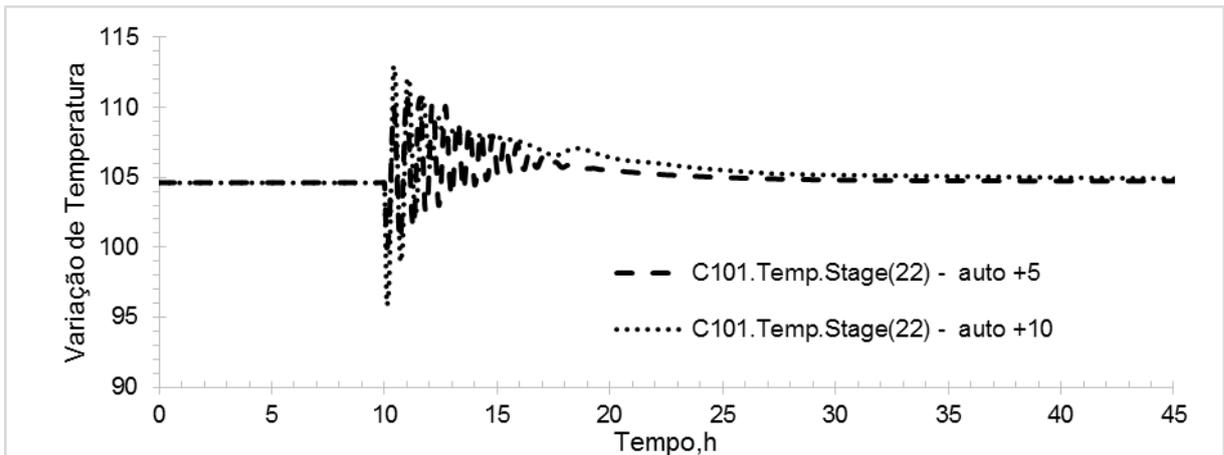
A Figura 23 mostra o comportamento para a temperatura do estágio 7 da “C102”. De maneira semelhante ao observado na Figura 22, o amortecimento da temperatura foi mais eficiente para o distúrbio de + 10, visto que alcançou a estabilidade em aproximadamente 80 h, comparando com a estabilização próxima de 120 h para a variação de +5%, sendo que ambas estabilizaram a uma temperatura em torno de 166 °C.

Figura 23 - Variação da Temperatura do estágio 7 da “C102” com o tempo.



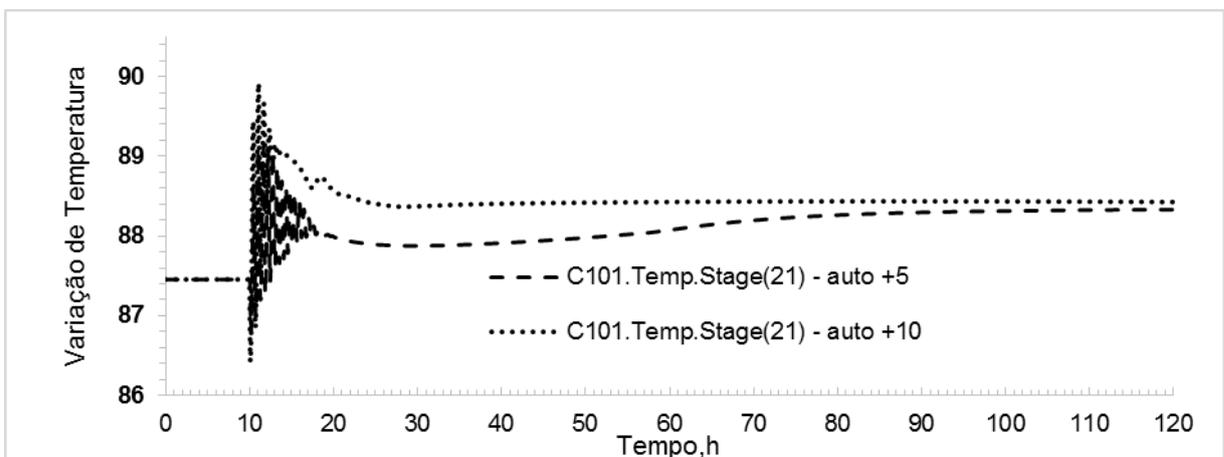
A Figura 24 apresenta a variação para a temperatura do estágio 22 da coluna “C101”. Observa-se para o gráfico da temperatura 22 comportamento semelhante aos gráficos anteriores, quanto a característica de amortecimento com a comparação entre os distúrbios +5% e +10%. Vale salientar que a temperatura do estágio 22 retornou ao ponto estacionário bem mais rápido que as temperaturas 8 e 7 da coluna “C102”.

Figura 24 - Variação da Temperatura do estágio 22 da “C101” com o tempo.



A Figura 25 apresenta o comportamento para a temperatura do estágio 21 da coluna “C102”. Observa-se, no gráfico da Figura 24, que a resposta da temperatura, para o distúrbio de +5%, é mais lenta no tocante a alcançar o estacionário, quando comparado ao caso +10%. Entretanto, vê-se que em ambos os casos, a estabilização ocorre em um valor pouco acima do valor inicial.

Figura 25– Variação da Temperatura do estágio 21 da “C101” com o tempo.



Uma vez avaliado o comportamento das variáveis controladas do processo, foram plotados os gráficos referentes as variações das composições determinadas, de maneira semelhante ao realizado para a variação das temperaturas.

As Figuras 26, 27 e 28 apresentam, respectivamente, o comportamento das composições de etanol, na corrente de destilado da “C101”, água na corrente de destilado da “C102” e solvente na corrente de base da coluna” C102”.

Analisando o gráfico da Figura 26, observa-se que, para ambos os distúrbios, o sistema de controle consegue alcançar o valor determinado para a composição de etanol anidro, sendo que a variação, para o distúrbio +10 apresenta uma maior característica de amortecimento.

A Figura da variação da composição da água apresentado na Figura 27, mostra que ambos os distúrbios alcançaram pontos estacionários um pouco afastado do valor inicial da composição da água, apresentando caráter de amortecimento semelhante ao da Figura 26.

Já a figura 28, referente ao comportamento da fração de solvente, mostra que em ambos os casos, o sistema de controle consegue retornar o valor de fração para os valores iniciais.

Figura 26 - Variação da Composição de etanol na corrente de destilado da “C101” com o tempo.

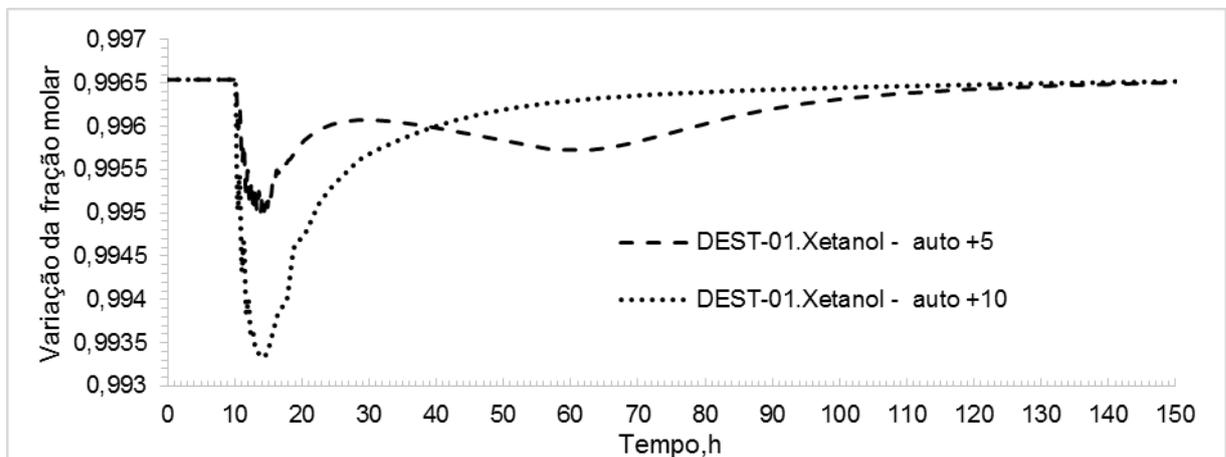


Figura 27 – Variação da Composição de água na corrente de destilado da “C102” com o tempo.

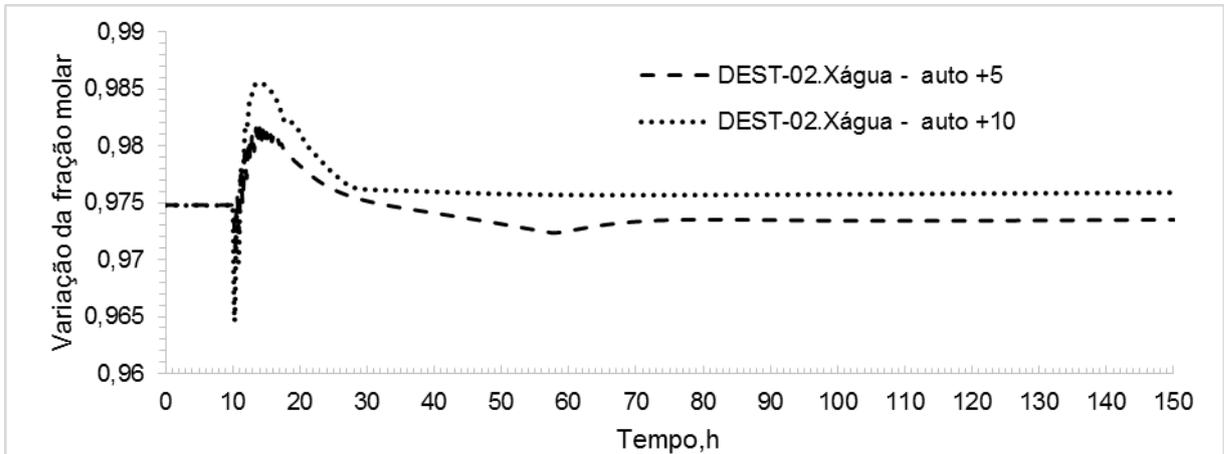
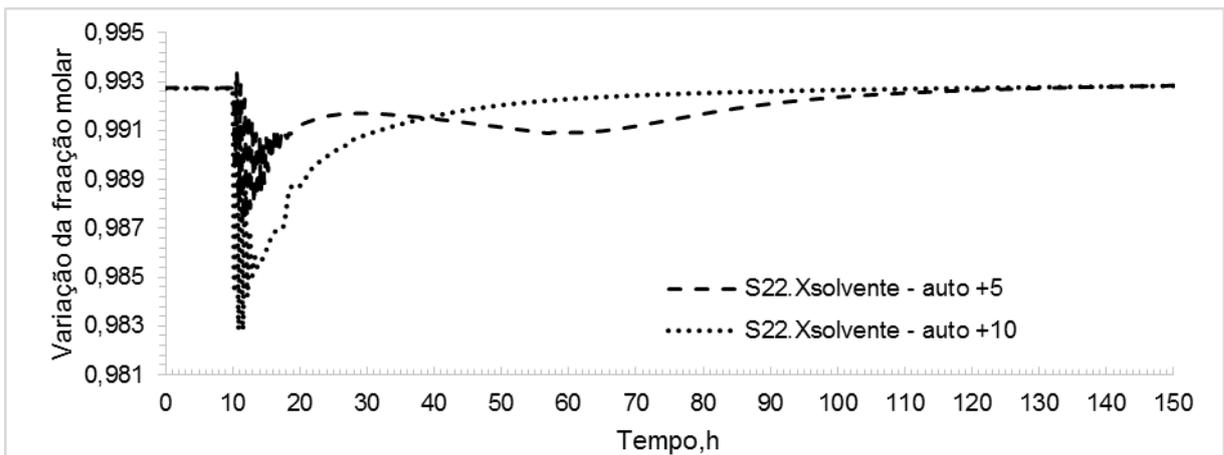
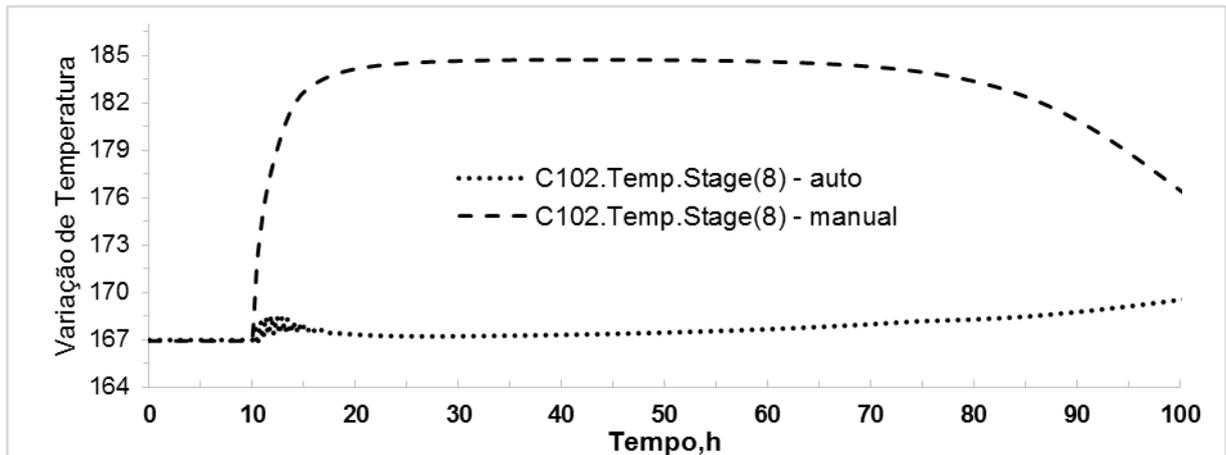


Figura 28 – Variação da Composição de solvente na corrente de base da “C102” com o tempo.



Realizados os distúrbios positivos apresentados nas Figuras 22 até 28, e com o objetivo de testar a capacidade regulatória do sistema de controle proposto, foi realizado o distúrbio negativo de 1% no fluxo de alimentação de etanol a 85 %. As Figuras 29, 30, 31 e 32 apresentam os comportamentos das temperaturas T8, T7, T22 e T21 e as Figuras 33, 34 e 35 apresentam as comportamentos das composições de etanol, na corrente de destilado da “C101”, água na corrente de destilado da “C102” e solvente na corrente de base da “C102”. Nessa etapa foram comparadas as variações a partir da utilização dos controlados nos modos manual e automático. A não utilização dos distúrbios negativos, de maior amplitude, foi devido ao surgimento de um caráter muito oscilatório, para distúrbios negativos em torno de -5%, causando a não convergência do sistema.

Figura 29 – Variação da Temperatura do estágio 8 da “C102” com o tempo.



Para a variação da temperatura do estágio 8, a Figura 29 mostra que o sistema de controle consegue absorver o distúrbio negativo de 1%, aplicado no tempo igual a 10 h. Na Figura V9 fica evidente a importância do sistema de controle, visto que o mesmo apresenta uma variação muito expressiva em malha aberta.

A variação da temperatura, apresentada na Figura 30, se mostrou bastante semelhante ao apresentada na Figura 29. Esse fato pode ser justificado pela proximidade entre os pratos de equilíbrio das duas temperaturas

Figura 30 - Variação da Temperatura do estágio 7 da “C102” com o tempo.

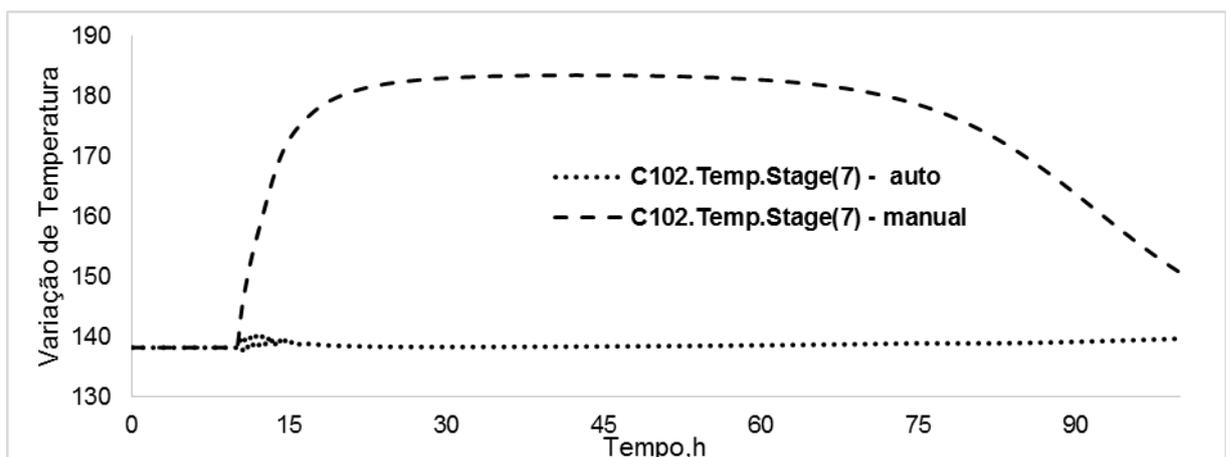
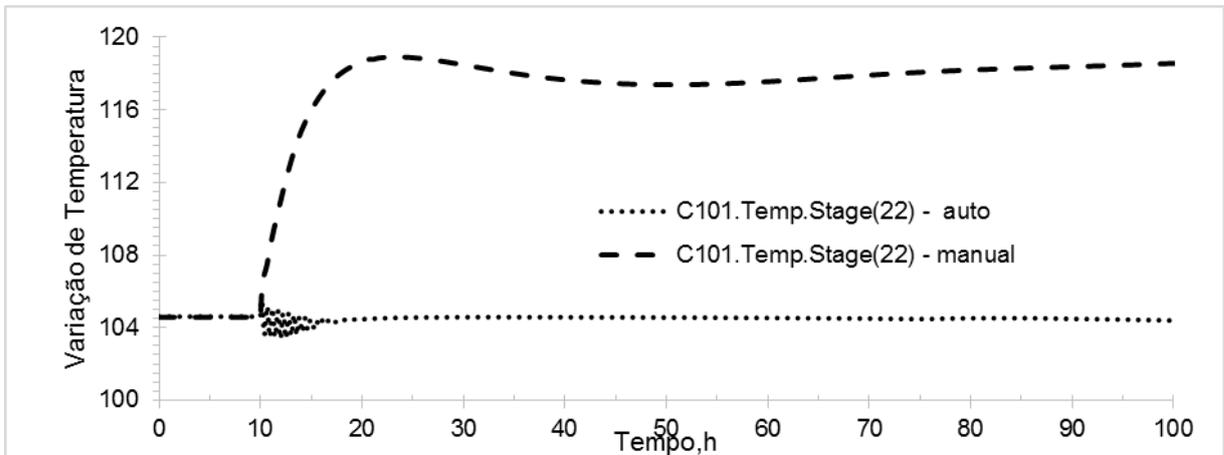
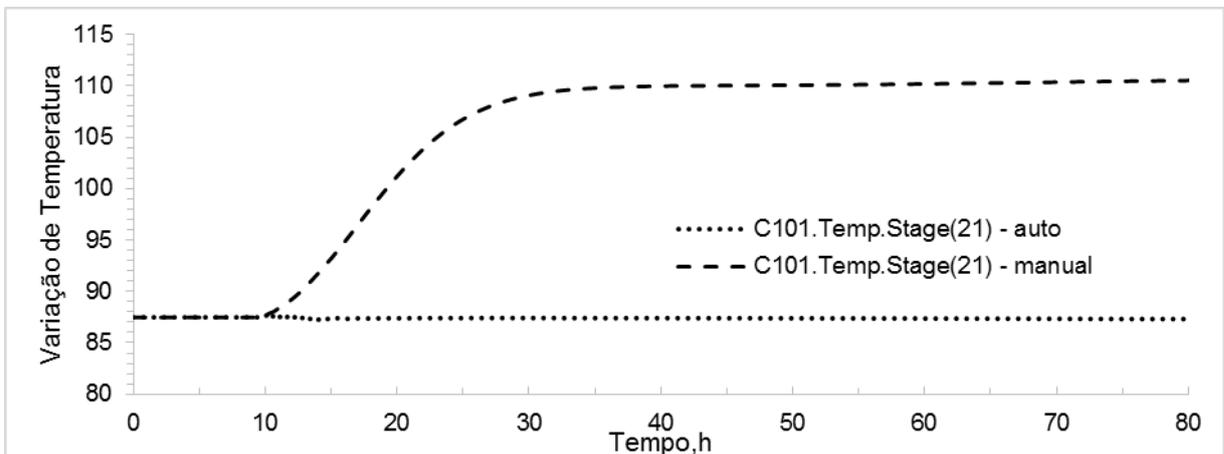


Figura 31 - Variação da Temperatura do estágio 22 da “C101” com o tempo.



As variações das temperaturas 22 e 21, respectivamente, Figuras 31 e V32, também apresentaram caráter semelhante, tanto na capacidade do sistema de controle bem como no caráter oscilatório da sua variação em malha aberta. Entretanto, o comportamento da temperatura do estágio 21 se mostrou bem menos oscilatório, quando comparado a variação da temperatura do estágio 22.

Figura 32 - Variação da Temperatura do estágio 21 da “C101” com o tempo.



Os gráficos das variações das composições, Figuras 33, 34 e 35, mostram que o sistema de controle foi eficiente em manter os valores de composição próximos dos valores iniciais. A composição de etanol apresentou tendência de afastamento a partir de 40 h de simulação. Já a fração de água não sofreu muita interferência do distúrbio aplicado. A fração de solvente, Figura 35 apresenta comportamento semelhante a variação da fração da água, porém apresenta uma tendência oscilatório a partir de 40 h de simulação.

Figura 33– Variação da Composição de etanol no destilado da “C101” com o tempo.

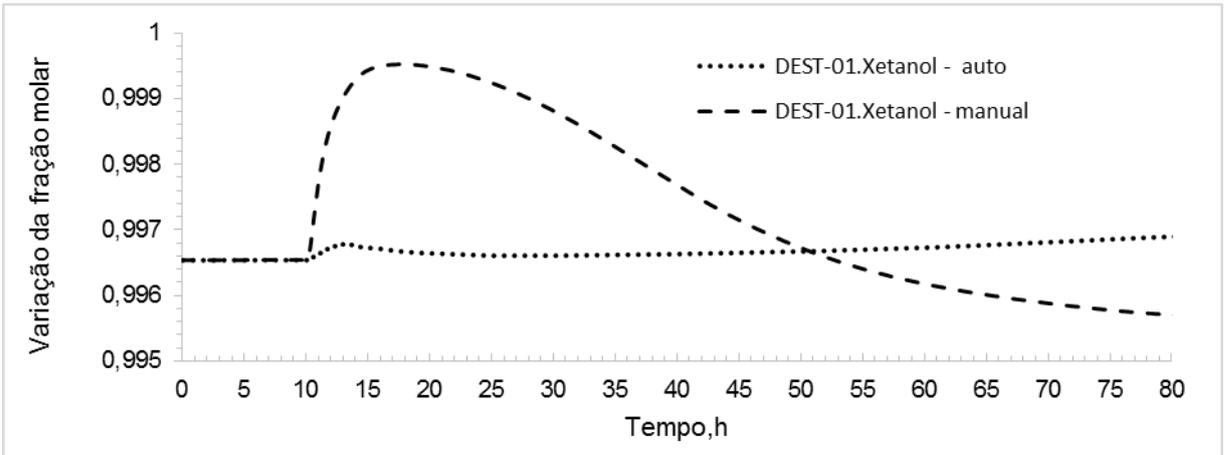


Figura 34 - Variação da Composição de água no destilado da “C102” com o tempo.

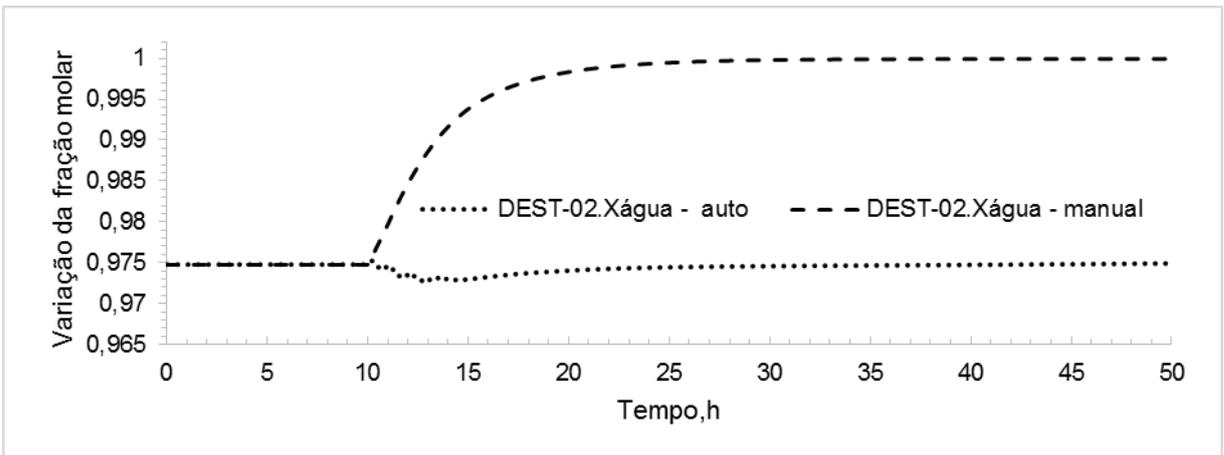
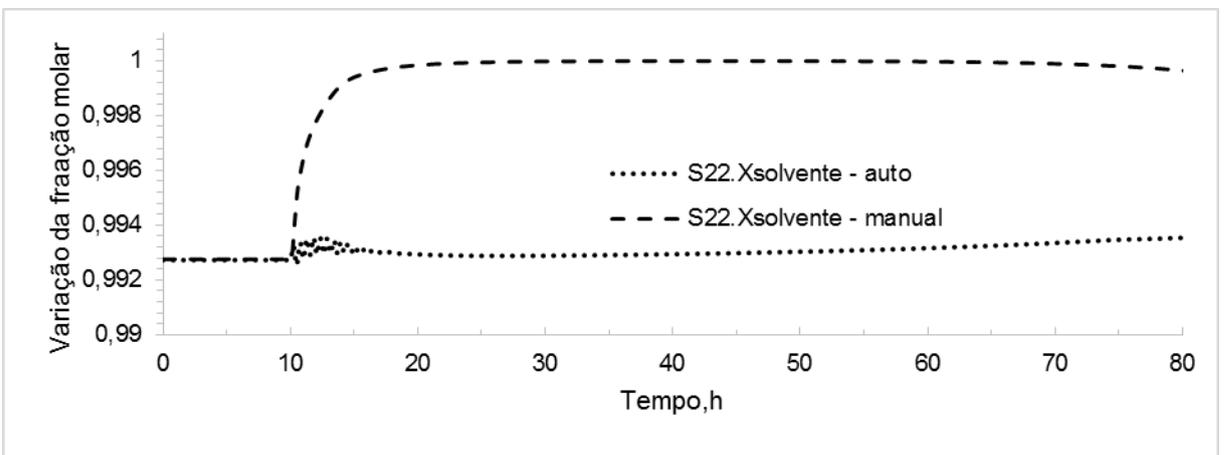


Figura 35 - Variação da Composição de solvente na corrente de base da “C102” com o tempo.



7. CONCLUSÕES

Realizados todos as etapas determinadas nos objetivos desse trabalho, foi observado que, os sinais estimados, pela metodologia clássica, apresentam inversões de fase e erro de amplitude, coincidindo com o apresentado pela literatura.

Os erros de estimações apresentados pelos algoritmos ICA, nas figuras 6, 7 e 8, foram comprovados através dos resultados apresentados, com a comparação entre os sinais estimados pelos os algoritmos: *FastICA*, *JADE* e *ICA por PCA* e um conjunto de sinais de referência, gerados em plataforma *Matlab*®.

As diferenças de estimação, quando comparando os resultados da correção proposta e da estimação convencional, mostrada nas figuras 16, 17 e 18 evidenciam, ainda mais, e eficiência da correção proposta.

Como resultado mais expressivo, tem-se que a consideração de matrizes circulantes, realizada na matriz de branqueamento, provocou uma maior descorrelação/independência da matriz de sinais misturados. Sendo, essa “maior descorrelação” responsável pela melhor convergência do Algoritmo ICA por PCA, podendo então ser denominada de técnica MOD-ICA.

A correção proposta foi eficiente em melhorar a convergência do algoritmo ICA por PCA, mostrando uma correção de amplitude bastante significativa, como mostrado na Figura 15. Dessa forma a inserção do termo $1/\sqrt{n}$, onde n é o número de sinais, como ponderador na matriz de branqueamento pode ser utilizado para correção da amplitude dos sinais estimados.

Foi observado que a utilização da metodologia de desacoplamento, pela a técnica MOD-ICA, possibilitou, além de um novo emparelhamento, do sistema de controle, em comparação ao emparelhamento fornecido pela a SVD clássica, em uma redução do número condicional do sistema, indicando uma maior controlabilidade, menor grau de incerteza e maior desacoplamento do sistema. A análise da Matriz de ganhos relativos, foi importante para a identificação das malhas de controle que estavam provocando instabilidade no sistema, além de indicar emparelhamentos não indicados pela SVD. Observa-se também que a aplicação do sistema de desacoplamento, e eliminação das malhas instáveis, resultou em valores de ganho relativos mais satisfatórios e, conseqüentemente, em um sistema de controle mais estável, além da eliminação das PV's referentes as composições

Os resultados obtidos com a utilização do Aspen Dynamics®, contendo as respostas aos distúrbios positivos de 5% e 10% e para o distúrbio negativo de -1, mostram que a técnica MOD-ICA pode ser utilizada como ferramenta de desacoplamento para sistemas de controle multivariado apresentando ainda bons resultados quanto a eficiência na amortização dos distúrbios na alimentação de etanol.

8. REFERÊNCIAS

AITEN, W. E. *Studies on control of integrated plants*. 1994. Thesis of Doctor Engineering University of Trondheim, Norwegian Institute of Technology. 1995.

AL-HASANAT, A.; MESLEH, A.; KRISHAN, M.; SHARADQH, A.; AL-QAISI, A.; WOO, W.L. Blind separation of multicomponent seismic wavefield using SVD of reduced dimension spectral matrix. *Journal of King Saud University - Computer and Information Sciences*, v.29, Issue 1, p.39-53, 2017.

ANJOS, D. A.; SILVA, J. N. Aplicação das Técnicas SVD e RGA no Projeto de Malhas de Controle. In: CONGRESSO NACIONAL DE PESQUISA E ENSINO EM CIÊNCIAS, 2016 Campina Grande.

ASMAR, N. B. *Control of a two refrigeration system*. 1995. Thesis of doctor of philosophy, University of Nottingham. 1999.

BAI, P.; SHEN, H.; HUANG, X.; TROUNG, Y. A. Supervised Singular Value Decomposition for independent Component Analysis of fMRI. *Statistica Sinica*, 2008

BELTRAMI, E. Sulle Funzioni Bilineari. *Giornale di matematiche ud uso Degli Studenti Delle Universita*, v.11, p. 98 – 106, 1873.

BIRBAUMER N., L.G. COHEN, Brain-computer interfaces: Communication and restoration of movement in paralysis, *J.Physiol*, v. 579, no 3, p. 621-636, 2007.

BIZON, K., CONTINILHO, G., LOMBARDI, S., SEMENTA, P. Independent componente analysis of cycle resolved combustion images from a spark ignition optical engine. *Combustion and Flame*, v.163, p.258-269, 2016.

BODE H., C. SHANNON, “A simplified derivation of Linear least squares smoothing and prediction theory”, *Proc. IRE*, Vol. 38, pag. 417-425, Apr 1950.

BRISTOL, E.H. On a new measure of interaction for multivariable process control, *IEEE Transactions on Automatic Control*, p.51 – 56, 1966

CARDOSO, J. F. Source separation using higher order moments. In: INTERNATIONAL CONFERENCE ON ACOUSTICS, SPEECH, AND SIGNAL

PROCESSING, 89., 1989, Glasgow. Proceedings... Glasgow: IEEE, 1089. p. 2109-2112.

CARDOSO, J. F.; SOULOUMIAC, A. Blind beamforming for non Gaussian signals. *IEE Proceedings - Part F, London*, v. 140, n. 6, p. 362-370, Dec. 1993.

CARMO, S. K. S, VASCONCELOS, L. G. S. EMERENCIANO, M. da S. A. Aplicação da análise de componentes independentes (ICA) no controle de uma coluna de destilação de alta pureza. In: XX Congresso Brasileiro de Engenharia Química, Florianópolis, SC, 2014.

Chen, B. & Lei, Z., Equilibrium-Based Separation Technologies: Part II. *Separation and Purification Technologies in Biorefineries*, First Edition, 2013.

CHEN, P.; ZHANG, W. Improvement on na inverted decoupling technique for a class of stable linear multivariable processes. *ISA Transactions*, v. 46, p. 199-210, 2007.

CICHOCKI, A., AMARI, S-I. Adaptive Blind Signal and Image Processing: Learning Algorithms and Applications. John Wiley & Sons, 2002.

COKER, A. K. Ludwig's Applied Process Design for Chemical and Petrochemical Plants. Oxford, United Kingdom, 2007.

COMON, P. Independent component analysis, a new concept? *Signal Processing*, Amsterdam, v. 36, n. 3, p. 287-314, 1994.

COVER, T. M.; THOMAS, J. A. Elements of information theory. New York: J. Wiley, 1991. 542 p.

DAMASCENO N. C, MEDEIROS A. M., Blind Source Separation using genetic algorithms end negentropy as separation measure. In: XLII SBPO, Bento Gonsalves, RS, 2010.

DAMASCENO N. C, MEDEIROS A. M., MARTINS ALLAN de M., Um Algoritmo de Otimização Para Maximizar a Negentropia de Rényi Aplicado ao problema Blind Source Separation Não Linear. In: XLV SBPO, Natal, RN, 2013.

ECKART, C.; YOUNG, G. A Principal Axis Transformation for Non-Hermitian Matrices. *Bulletin of the American Mathematical Society*, v. 45, p. 118 – 121, 1939.

FAVERO, Jovani L., SILVA, LUIZ FERNANDO L.R, LAGE, PAULO L.C., Comparison of methods for multivariate moment inversion – Introducing independent component analysis. *Computers and Chemical Engineering*, v.60, p.41-56, 2014.

GAGNON, E.; POMERLEAU, A; DESBIENS, A. Simplified, ideal or inverted decoupling? IN: ISA TRANSACTIONS, 1998, p. 265-276.

GARRIDO, J.; VAZQUEZ, F; MORILLA, F. Na extended approach of inverted decoupling. *Journal of Process Control*, v.21, 2011.

GROSDIDIER P.; MORARI M.; HOLT B. R.. Closed-loop from steady-state gain information. *Industrial and engineering Chemistry fundamental*, v. 24, p. 221-235, 1985.

HAYKIN S., “*Adaptive Filter Theory*”, 4th ed., Prentice-Hall, Englewood Cliffs, NJ, 2001b.

HERAULT, J.; JUTTEN, C. Space or time adaptive signal processing by neural network models: neural networks for computing. In: CONFERENCE OF THE AMERICAN INSTITUTE OF PHYSICS, 1., 1986, New York. Proceedings... New York: AIP, 1986. p. 206-211.

HERAULT, J.; JUTTEN, C.; ANS, B. Détection de grandeurs primitives dans un message composite par une architecture de calcul neuromimétique en apprentissage non supervisé. In: XÈME COLLOQUE GRETSI, 1., 1985, Paris. **Actes**. Paris: GRETSI, 1985. p. 1017-1022.

HYVÄRINEN A., “*Fast and robust Fixed-point algorithms for independent component analysis*”. IEEE Trans. Neural Networks 10, 1999b.

HYVÄRINEN A., “Survey on independent component analysis”, Neural Computer Surveys 2, 1999a.

HYVÄRINEN A., E. OJA. “*Independent Component Analysis: Algorithms and applications Neural Networks*”, 2000.

HYVÄRINEN A., E.OJA. “*Independent component analysis: A tutorial*”. Technical report, 1999.

HYVÄRINEN, A., KARHUNEN, J., OJA, E. Independent Component Analysis, Wiley interscience Publication, 2001.

JORDAN, C. Memoire sur les formes bilinéaires. *Journal de Mathématiques Pures et Appliquées, Deuxième Serie*, v. 19, p. 35 – 54, 1874.

JOSEPH, B.; BROSILOW C.B. Inferential control of processes. *AIChE Journal* v.22. p. 485-492, 1978.

JUTTEN, C.; HERAULT, J. Blind separation of sources, part I: an adaptive algorithm based on neuromimetic architecture. *Signal Processing*, Amsterdam, v. 24, n. 1, p. 1-10, 1991.

KAI S., W. QI, AND D. MINGLI. Approach to nonlinear blind source separation based on niche genetic algorithm. In: *Proceeding of the Sixth International Conference on Intelligent Systems Design and Applications (ISDA'06)*, Jinan, China, 2006.

KULLBACK, S.; LEIBLER, R. A. (1951) On information and sufficiency. *The Annals of Mathematical Statistics*, 22, 79-86.

KUN Z, Lai – WAN CHAN, “*ICA by PCA Approach: Relating Higher-Order Statistics to Second-Order Moments*”, 2006.

LEITE, I.C.C., SÁFADI, T., CARVALHO, M.L.M. Evaluation of seed radiographic images by independent component analysis and discriminant analysis. *Seed Science and Technology*, v. 41, n 2, p.235-244, july 2013

LEITE. L., Análise de Componentes Independentes aplicada à Identificação de Regiões lesionadas em mamogramas, In: *Proceeding of II Congresso Latino-Americano de Engenharia Biomédica*, pp. 105, João Pessoa – PA – Brasil, 2004.

LIANFANG CAI, XUEMIN TIAN, Ni ZHANG. A Kernel Time Structure Independent Component Analysis Method for Nonlinear Process Monitoring. *Chinese Journal of Chemical Engineering*, v. 22, Issues 11–12, p.1243-1253, November 2014.

LU XIAN, KAIJIAN He, KIN KEUNG LAI. Gold price analysis based on ensemble empirical model decomposition and independent component analysis, *Physica A: Statistical Mechanics and its Applications*, v. 454, p. 11-23, July 2016.

LUYBEN, W. L. Distillation decoupling. *AiChE Journal*, v. 16, n.2, p. 198-203, 1970.

- LUYBEN, W. L. Process modeling, simulation and control for chemical engineers. McGraw-Hill. Chemical Engineering Series, 2th Ed. 1990
- MARLIN, T. E. Interaction analysis theory and application. *ISA Monograph Series 6. Research Triangle Park*, N.C. 1995.
- MOORE, C.; HACKNEY. J.; CANTER, D. Selecting Sensor location and Type for Multivariable Process. University of Tennessee, 1986.
- MORETO, F. A. de L., *Análise de componentes independentes aplicada à separação de sinais de áudio. Dissertação de mestrado*. Departamento de Engenharia de Sistemas Eletrônicos. Universidade de São Paulo, 2008.
- NAIK G. R., Introduction: Independent Component Analysis. In: NAIK G. R. *Independent Component Analysis for Audio and Biosignal Applications*. Croatia, 2012. p. 3 – 23.
- NETT, C. N.; MANOUSIOUTHAKIS, V. Euclidean condition and block relative gain: connections, conjectures, and clarifications. *IEEE Transactions on Automatic Control* v.32 p. 405-407, 1987.
- OGUNNAIKE, B. A. Process dynamics modeling and control. Oxford University, 1994.
- OGUNNAIKE, B. A.; RAY, W. H. Process dynamics modeling and control. *Oxford University Press*. Oxford UK, 1995.
- PORDANKANI, I.R.; XU, W. A singular value decomposition-based technique for decoupling and analyzing power networks. *International Journal of Electrical Power & Energy Systems*, v. 74, P 265-273, 2016.
- RAMOS, W., B., *Dinâmica e controle do processo de obtenção de etanol anidro via destilação extrativa com integração térmica*. 2016. Tese de doutorado em engenharia química da universidade federal de campina grande, Campina grande, Brasil, 2006.
- SHINSKEY, F. Process Control Systems: Application, Design and Adjustment. [S.I.]: MacGraw-Hill, 1988.
- SILVA, A.P.O. da, GUERREIRO, A.M.G., DÓRIA, A.D. FPGA hardware design, simulation and synthesis for a independent component analysis algorithm using system-level design software." *Proc. Int. Multi-Conf. Complexity, Informatics and Cybernetics*. 2010

SOUSA, B. M. DE, HUGO C. C., MICHEL, ANÍSIO R. BRAGA, ANDRÉ P. LEMOS, WEBBER E. P. AGUIAR, CARMELA M. P. BRAGA. Controle Estatístico Multivariado de uma Caldeira com Múltiplos Pontos de Operação. In: ANAIS DO XX CONGRESSO BRASILEIRO DE AUTOMÁTICA. Belo Horizonte. 2014. *Anais Eletrônicos*. Belo Horizonte, 2014.

STOEV. J.; OMEN, T. SCHOEKENS, J. Tensor methods for MIMO decoupling using frequency response functions. *IFAC-PapersOnLine*, v. 49, p. 447-453, 2016

SUDIBYO, I.M.; IQBAL, M.N.; MURAT, N. A. Comparison of MIMO MPC and PI Decoupling in Controlling Methyl Tert-butyl Ether Process, IN: IFTEKHAR A. KARIMI AND RAJAGOPALAN SRINIVASAN, 2012, v. 31, p. 345-349, 2012.

SVRCEK, W. Y.; MAHONEY, D. P.; YOUNG, B. R. A Real - Time Approach to Process Control. *John Wiley & Sons*, 2º. ed., v.2, 2006.

SYLVESTER, J. J. A new proof that a general quadric may be reduce to its canonical form (that is, a linear function of squares) by means of a real orthogonal substitution. *Messenger of Mathematics*, v. 19, p. 1 – 5, 1889.

THAM, M. T. Multivariable control an introduction to decoupling control. Departament of Chemical and Process Engineering, University of New Castle upon tyne. Published originally as Chapter 8 in *Industrial digital control systems*. Eds. K. Warwick and D. Ress, *IEE Control Engineering Series 37*, Peter Peregrinus, 1999.

TRIERWEILER, J. O. A Systematic Approach to Control Structure Design. 1997. Tese de Doutorado, Departamento de Engenharia Química, Universidade de Dortmund. Dortmund, 1997.

VRABIE, V.; MARS, J. I.; LACOUME, J. –L.. Modified Singular Value Decomposition by Means of Independent Component Analysis. Elsevier Science, 2003.

WADE, H. L. Inverted decoupling: a neglected technique. *ISA Transactions*, v. 36, n.1, p. 3-10, 1997

WANG, B., YAN, X., JIANG, Q., Independent component analysis model utilizing de-mixing information for improved non- Gaussian process monitoring. *Computer & Industrial Engineering*, v. 94, p.188-200, 2016.

WIENER N., “*Extrapolation, Interpolation and Smoothing of Stationary Time Series, With Engineering Applications*”, Wiley, NY, New York, 1949.

YINGWEI ZHANG, YANG ZHANG, Fault detection of non-Gaussian processes based on modified independent component analysis. *Chemical Engineering Science*, v. 65, Issue 16, p.4630-4639, August 2010.

YOSHIOKA M., S. OMATU, “*Signal separation metho using genetic algorithms*”, in Proc. IEEE Int. Joint Conf. Neural Networks, vol. 2, pp. 909-912, 1998.

YUNG-KUN CHUANG, Yi-PING Hu, I-CHANG YANG, STEPHEN R. Delwiche, Yangming MARTIN Lo, CHAO-YIN Tsai, Suming Chen, Integration of independent component analysis with near infrared spectroscopy for evaluation of rice freshness, *Journal of Cereal Science*, v. 60, Issue 1, p.238-242, July 2014.

ZHANG, Fuzhen. *Matrix Theory: Basic Results and Techniques*.1. ed. New York: Springer, 1999.