



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21c/2018/03.28.12.42-TDI

CLASSIFICAÇÃO INTELIGENTE DE SUPERNOVAS UTILIZANDO SISTEMAS DE REGRAS NEBULOSAS

Luis Ricardo Arantes Filho

Dissertação de Mestrado do
Curso de Pós-Graduação em
Computação Aplicada, orientada
pelo Dr. Lamartine Nogueira
Frutuoso Guimarães, aprovada em
20 de abril de 2018.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/3QQD3EB>>

INPE
São José dos Campos
2018

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GBDIR)

Serviço de Informação e Documentação (SESID)

Caixa Postal 515 - CEP 12.245-970

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/6921

E-mail: pubtc@inpe.br

**COMISSÃO DO CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO
DA PRODUÇÃO INTELECTUAL DO INPE (DE/DIR-544):****Presidente:**

Maria do Carmo de Andrade Nono - Conselho de Pós-Graduação (CPG)

Membros:

Dr. Plínio Carlos Alvalá - Centro de Ciência do Sistema Terrestre (COCST)

Dr. André de Castro Milone - Coordenação-Geral de Ciências Espaciais e Atmosféricas (CGCEA)

Dra. Carina de Barros Melo - Coordenação de Laboratórios Associados (COCTE)

Dr. Evandro Marconi Rocco - Coordenação-Geral de Engenharia e Tecnologia Espacial (CGETE)

Dr. Hermann Johann Heinrich Kux - Coordenação-Geral de Observação da Terra (CGOBT)

Dr. Marley Cavalcante de Lima Moscati - Centro de Previsão de Tempo e Estudos Climáticos (CGCPT)

Silvia Castro Marcelino - Serviço de Informação e Documentação (SESID)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon

Clayton Martins Pereira - Serviço de Informação e Documentação (SESID)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Simone Angélica Del Duca Barbedo - Serviço de Informação e Documentação (SESID)

Yolanda Ribeiro da Silva Souza - Serviço de Informação e Documentação (SESID)

EDITORAÇÃO ELETRÔNICA:

Marcelo de Castro Pazos - Serviço de Informação e Documentação (SESID)

André Luis Dias Fernandes - Serviço de Informação e Documentação (SESID)



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21c/2018/03.28.12.42-TDI

CLASSIFICAÇÃO INTELIGENTE DE SUPERNOVAS UTILIZANDO SISTEMAS DE REGRAS NEBULOSAS

Luis Ricardo Arantes Filho

Dissertação de Mestrado do
Curso de Pós-Graduação em
Computação Aplicada, orientada
pelo Dr. Lamartine Nogueira
Frutuoso Guimarães, aprovada em
20 de abril de 2018.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/3QQD3EB>>

INPE
São José dos Campos
2018

Dados Internacionais de Catalogação na Publicação (CIP)

Arantes Filho, Luis Ricardo.

Ar14c Classificação inteligente de supernovas utilizando sistemas de regras nebulosas / Luis Ricardo Arantes Filho. – São José dos Campos : INPE, 2018.

xxiv + 161 p. ; (sid.inpe.br/mtc-m21c/2018/03.28.12.42-TDI)

Dissertação (Mestrado em Computação Aplicada) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2018.

Orientador : Dr. Lamartine Nogueira Frutuoso Guimarães.

1. Supernovas. 2. Classificação automática. 3. Inteligência artificial. 4. Lógica nebulosa. 5. Supernova do tipo Ia. I.Título.

CDU 004.8:524.352



Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).

Aluno (a): *Luis Ricardo Arantes Filho*

Título: "CLASSIFICAÇÃO INTELIGENTE DE SUPERNOVAS UTILIZANDO SISTEMAS DE REGRAS NEBULOSAS".

Aprovado (a) pela Banca Examinadora em cumprimento ao requisito exigido para obtenção do Título de **Mestre** em **Computação Aplicada**

Dr. **Stephan Stephany**



Presidente / INPE / SJCampos - SP

() Participação por Video - Conferência

Dr. **Lamartine Nogueira Frutuoso Guimarães**



Orientador(a) / INPE / SJCampos - SP

() Participação por Video - Conferência


Dr. **Reinaldo Roberto Rosa**



Membro da Banca / INPE / SJCampos - SP

() Participação por Video - Conferência

Dr. **Alexandre Soares de Oliveira**



Convidado(a) / UNIVAP / São José dos Campos - SP

() Participação por Video - Conferência

Dr. **Marcelo Módulo**



Convidado(a) / UMESP / São Bernardo do Campo - SP

() Participação por Video - Conferência

Este trabalho foi aprovado por:

() maioria simples

unanimidade

São José dos Campos, 20 de abril de 2018

“Eu vejo a ciência como um verdadeiro ato de disciplina espiritual”.

Dedico primeiramente a Deus. Dedico aos meus pais Luiz Ricardo Arantes e Magaly Arantes. Dedico ao meu irmão Victor Flávio Arantes e aos meus avós Rivanda Arantes e Walter Carneiro Arantes.

AGRADECIMENTOS

Agradeço a Deus.

Agradeço a minha família que sempre está comigo.

Agradeço ao prof. Lamartine N. F. Guimarães pela orientação, pelos ensinamentos e aprendizado constante durante a realização deste trabalho. Agradeço também pela confiança, pela paciência, atenção e dedicação depositadas durante a realização desta pesquisa. Sempre demonstrando ser um exemplo de profissional dedicado e honesto.

Agradeço ao prof. Reinaldo Roberto Rosa, pela orientação e pelos conhecimentos relacionados a astrofísica indicando pontos importantes no desenvolvimento deste trabalho.

Agradeço ao Dr. Marcelo Módolo pelos conhecimentos e contribuições relacionadas aos sistemas classificadores de supernovas Ia.

Agradeço aos Amigos Marcos e Bárbara pela amizade durante o curso.

Agradeço ao INPE pela oportunidade de desenvolver ciência e pesquisa para me tornar um cidadão melhor a cada dia.

Agradeço ao IEAv – DCTA (Instituto de Estudos Avançados), por me permitir usufruir das instalações e computadores para executar o desenvolvimento desta pesquisa.

Agradeço a secretaria da CAP, em especial a Jéssica, por sempre orientar e sanar as dúvidas sobre o programa de pós-graduação. Agradeço também a secretaria SPG.

Agradeço a CAPES – Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, pelo suporte financeiro permitindo que eu ajude minha família.

RESUMO

A teoria evolucionária das estrelas, dos estágios iniciais ao de supernovas, foi fundamentada com o uso da observação dos fenômenos e da análise por especialistas. As supernovas são o ciclo final da evolução estelar e, na maioria dos casos, resultam de uma explosão de colapso de núcleo ou, em apenas uma situação, de uma explosão termonuclear. Supernovas termonucleares, ou seja, supernovas de tipo Ia são objetos de estudo de diversas áreas da astrofísica e cosmologia, principalmente, por causa de seu brilho característico que pode ser utilizado na medição de distâncias astronômicas. A classificação deste fenômeno pode ser construída pela análise visual de um astrônomo que identifica no espectro óptico as linhas espectrais de elementos como o Hidrogênio (H), o Silício (Si) e o Hélio (He). Em classificações mais refinadas podem ser avaliadas a abundância de outros elementos. Este tipo de classificação não é trivial e depende tanto da especialidade do astrônomo como da qualidade dos dados. Uma das formas de tratar este problema foi desenvolvida por Módolo (2016), utilizando redes neurais do tipo perceptron de múltiplas camadas, com aprendizado por retropropagação do erro, para a classificação de supernovas de forma a simular a maneira humana de análise do espectro óptico resultando no classificador CIntIa(Classificador Inteligente de supernovas do Tipo Ia). Este classificador apresentou índices relevantes de acertos na identificação de supernovas de Tipo Ia. Neste sentido, este trabalho apresenta um método para a análise e classificação de supernovas, em específico, supernovas de Tipo Ia, que explora o paradigma de lógica nebulosa da inteligência artificial e o processamento dos sinais espectrais. A lógica nebulosa, neste caso, é usada para simular a forma como o astrônomo classifica supernovas termonucleares, proporcionando uma classificação automática e identificando as peculiaridades envolvidas no fenômeno, bem como sua evolução temporal. O modelo desenvolvido neste trabalho é denominado SUZAN, sigla para “Sistema fUZzy Avaliador de superNovas”. SUZAN e CIntIa são sistemas projetados para o trabalho em conjunto para garantir a classificação e a identificação acurada de supernovas de Tipo Ia. A necessidade de dois ou mais classificadores vem, da aplicação destes sistemas em uma situação que requer a operação de maneira automática e isolada, onde não existe um especialista para manipular os sistemas e validar a classificação, neste caso, os sistemas providenciam uma redundância na identificação de supernovas. Como resultado é demonstrado o desempenho do modelo para a classificação de 3697 espectros de 588 supernovas diferentes, atingindo um índice de precisão e acurácia de 96,4% para a classificação das supernovas de tipo Ia.

Palavras-chave: Supernovas. Classificação automática. Inteligência artificial. Lógica nebulosa. Supernova de Tipo Ia.

INTELLIGENT SUPERNOVAE CLASSIFICATION USING SYSTEMS OF FUZZY RULES

ABSTRACT

The evolutionary theory of the stars, from the early stages to supernovae, was based on the use of phenomena observation and analysis by specialists. Supernovae are the final cycle of stellar evolution and, in most cases, result from an explosion of core collapse or, in only one situation, from a thermonuclear explosion. Thermonuclear supernovae, i.e., type Ia supernovae are object of study of several areas of astrophysics and cosmology, mainly, because of its characteristic brightness that can be used in the measurement of astronomical distances. The classification of this phenomenon can be constructed by the visual analysis of an astronomer who identifies in the optical spectrum the spectral lines of elements such as Hydrogen (H), Silicon (Si) and Helium (He). In more refined classifications the abundance of other elements can be evaluated. This type of classification is not trivial and depends on both the astronomer's specialty and the data quality. One of the ways to deal with this problem was developed by Módolo (2016), using multilayer perceptron neural networks, with learning by backpropagation algorithm, for the classification of supernovae in order to simulate the human way of optical spectrum analysis resulting in the CIntla classifier (Intelligent Type Ia supernova classifier) – from the Portuguese language - “Classificador Inteligente de supernovas do tipo Ia”. In this sense, this work presents a method for analysis and classification of supernovae, in particular, Type Ia supernovae, which explores the Fuzzy Logic paradigm of artificial intelligence and the processing of spectral signals. The Fuzzy Logic, in this case, is used to simulate the way the astronomer classifies thermonuclear supernovae, providing an automatic classification and identifying the peculiarities involved in the phenomenon, as well as its temporal evolution. The model developed is called Fuzzy System Appraiser of Supernovae – SUZAN, from the Portuguese Language “*Sistema fUZZy Avaliador de superNovas*”. SUZAN and CIntla are systems designed to work together to ensure the classification and accurate identification of Type Ia supernovae. The need for two or more classifiers comes from the application of these systems in a situation that requires the operation in an automatic and isolated manner, where there is no specialist to manipulate the systems and validate the classification, in this case, the systems provide a redundancy in the supernovae identification. As a result, the performance of the model for the classification of 3697 spectra of 588 different supernovae was demonstrated, reaching a precision and accuracy index of 96.4% for the classification of type Ia supernovae.

Keywords: Supernovae. Automatic classification. Artificial Intelligence. Fuzzy Logic. Type Ia supernovae.

LISTA DE FIGURAS

	<u>Pág.</u>
Figura 2.1 – Diagrama HR para estrelas próximas.....	13
Figura 2.2 – Fusão dos elementos no decorrer da evolução da estrela.....	14
Figura 2.3 – Evolução Estelar.....	15
Figura 2.4 – Esquema do colapso de núcleo em estrelas massivas.....	20
Figura 2.5 – Esquema para formação de supernovas Ia para sistemas binários compostos por anãs brancas e gigantes vermelhas.....	22
Figura 2.6 – Esquema para formação de supernovas Ia para sistemas binários compostos por anãs brancas.....	23
Figura 2.7 – Curvas de Luz de supernovas de Tipo Ia.....	25
Figura 2.8 – Supernova 1994D de Tipo Ia na fase de Brilho Máximo.....	28
Figura 2.9 – Curva de luz de supernovas Ia.....	29
Figura 2.10 – Fases espectrais da supernova SN 1998aq.....	30
Figura 2.11 – Diversidade das Curvas de luz de supernovas.....	31
Figura 2.12 – Supernova 1995F de Tipo Ib na fase de Brilho Máximo.....	32
Figura 2.13 – Supernova 2005az de Tipo Ic na fase de Brilho Máximo.....	33
Figura 2.14 – Supernova 2007ce de Tipo Ic na fase de Brilho Máximo.....	34
Figura 2.15 – Comparação das Supernovas Ic 2005az e 2007ce na fase de Brilho Máximo.....	35
Figura 2.16 – Supernova 2008bo de Tipo II na fase de Brilho Máximo.....	36
Figura 2.17 – Esquema de classificação de Turatto.....	37
Figura 2.18 – Características espectrais dos tipos clássicos de supernovas no período de brilho máximo.....	38
Figura 2.19 – Evolução Temporal do Espectro da Supernova SN 1994D.....	40
Figura 2.20 – Busca de gradientes para SN 1998aq.....	42
Figura 3.1 – Função de pertencimento para baixas temperaturas em °C.....	50
Figura 3.2 – Variáveis linguísticas para temperatura, representadas por funções de pertencimento.....	52
Figura 5.1 – Fluxo de Dados do Sistema de Dupla Filtragem.....	76
Figura 5.2 – Espectro (Sinal) original de supernova com os picos e vales encontrados.....	81
Figura 5.3 – Filtragem simples do espectro de supernova pelo Filtro de Savitzky-Golay.....	83
Figura 5.4 – Filtragem simples do espectro de supernova pelo Filtro Moving Average.....	84
Figura 5.5 – Filtragem simples do espectro de supernova pelo Filtro de Wiener.....	85
Figura 5.6 – Região ruidosa do sinal original.....	86
Figura 5.7 – Região ruidosa do sinal filtrado pelo filtro de Savitzky-Golay.....	86
Figura 5.8 – Filtragem dupla do espectro de supernova pelo Filtro de Savitzky-Golay.....	88
Figura 5.9 – Filtragem dupla do espectro de supernova pelo Filtro Moving Average.....	89
Figura 5.10 – Filtragem dupla do espectro de supernova pelo Filtro de Wiener.....	89
Figura 5.11 – Região ruidosa do sinal duplamente filtrado pelo filtro de Savitzky-Golay.....	90
Figura 5.12 – Correlação para os dados de Supernova.....	92

Figura 5.13 – O ajuste de Redshift nos espectros.....	93
Figura 5.14 – Espectro contínuo de corpo negro.....	97
Figura 5.15 – Espectro contínuo simulado pelo SUZAN.....	97
Figura 5.16 – Largura equivalente.....	99
Figura 5.17 – Parâmetro de Intensidade de Pico.....	100
Figura 6.1 – Variável nebulosa de largura equivalente e termos linguísticos.....	105
Figura 6.2 – Variável nebulosa de intensidade de pico e termos linguísticos.....	106
Figura 6.3 – Construção das regras nebulosas para análise das linhas Candidatas.....	109
Figura 6.4 – Linhas Candidatas.....	110
Figura 6.5 – Variável nebulosa de Distância Relativa e termos linguísticos.....	114
Figura 6.6 – Variável nebulosa de Linhas Espectrais Fuzzy.....	116
Figura 6.7 – Algoritmo nebuloso para avaliação de elementos.....	117
Figura 7.1 – Fases espectrais e dias de observação da supernova SN 1994D.....	122
Figura 7.2 – Plotagem dos espectros contidos no banco 1 de supernovas Ia no brilho máximo.....	132
Figura 7.3 – Supernova SN 1998dx modelo clássico de brilho máximo do tipo Ia: A-Ia_Fasel_1.....	134
Figura 7.4 – Supernova SN 2003ch modelo clássico de brilho máximo do tipo Ia: B-Ia_Fasel_2.....	134
Figura 7.5 – Supernova SN 1993cc modelo clássico de brilho máximo do tipo Ia: C-Ia_Fasel_3.....	135
Figura 7.6 – Supernova SN 1999ek modelo peculiar de brilho máximo do tipo Ia: D-Ia_peculiar_1.....	135
Figura 7.7 – Supernova SN 1999gd modelo peculiar de brilho máximo do tipo Ia: E-Ia_peculiar_2.....	136
Figura 7.8 – Supernova SN 2006gj modelo peculiar de brilho máximo do tipo Ia: F-Ia_peculiar_3.....	136
Figura 7.9 – Separação de modelos de supernovas Ia de brilho máximo de maneira não supervisionada.....	137
Figura 7.10 – Supernova SN 2003ch capturada pelo telescópio FLWO 1.5m+FAST. .	140
Figura 7.11 – Supernova SN 2003ch capturada pelo telescópio MMT 6.5m+Bluechannel.....	141

LISTA DE TABELAS

	Pág.
Tabela 5.1 – Fases de observação utilizadas.....	62
Tabela 5.2 – Organização dos dados espectrais de supernovas.....	63
Tabela 5.3 – Instrumentos de coleta de dados para o Banco 2.....	65
Tabela 5.4 – Instrumentos de coleta de dados para os Bancos 4,5 e 6.....	68
Tabela 5.5 – Organização dos dados espectrais de supernovas no Sistema CIntIa.....	70
Tabela 5.6 – Organização dos dados espectrais de supernovas no sistema CIntIa para treinamento da rede neural.....	71
Tabela 5.7 – Organização dos dados espectrais de supernovas no sistema CIntIa para teste da rede neural.....	72
Tabela 5.8 – Características do Sinal Original.....	81
Tabela 5.9 – Desempenho dos filtros no sistema de filtragem simples para o sinal de Supernova SN 1998aq, com o ruído inerente ao fenômeno.....	82
Tabela 5.10 – Desempenho dos filtros no sistema de filtragem Dupla para o sinal de Supernova SN 1998aq, com o ruído inerente ao fenômeno.....	87
Tabela 5.11 – Organização dos dados nos arquivos processados.....	101
Tabela 6.1 – Fuzzificação da Variável de Largura Equivalente.....	106
Tabela 6.2 – Fuzzificação da Variável de Intensidade de Pico.....	107
Tabela 6.3 – Linhas Espectrais de elementos utilizados no sistema SUZAN.....	113
Tabela 6.4 – Fuzzificação da Variável de Largura Equivalente.....	114
Tabela 6.5 – Linhas Espectrais de elementos utilizados no sistema SUZAN.....	115
Tabela 7.1 – Resposta da SUZAN para os bancos com todos os períodos de observação.....	125
Tabela 7.2 – Matriz de confusão para classificação de Supernovas Ia e Não Ia nos bancos com todas as observações.....	125
Tabela 7.3 – Índices de precisão para classificação de Supernovas Ia e Não Ia para todas as Observações.....	126
Tabela 7.4 – Separação dos Bancos de espectros no CIntIa.....	127
Tabela 7.5 – Resposta da SUZAN para os bancos separados no sistema CIntIa.....	128
Tabela 7.6 – Matriz de confusão para classificação de Supernovas Ia e Não Ia nos bancos separados pelo sistema CIntIa.....	128
Tabela 7.7 – Índices de precisão para classificação de Supernovas Ia e Não Ia para os dados do sistema CIntIa.....	129
Tabela 7.8 – Modelos de Supernova Ia para homogenização das amostras.....	133
Tabela 7.9 – Separação dos Bancos 2 e 3 com amostras normalizadas.....	138
Tabela 7.10 – Resposta da SUZAN para os bancos 2 e 3 para amostras normalizadas.....	138
Tabela 7.11 – Supernovas Ia peculiares encontradas nos Bancos 2 e 3 normalizados.....	142
Tabela 7.12 – Dados utilizados nos experimentos para os dois sistemas.....	143
Tabela 7.13 – Tabela de validação para dupla redundância dos sistemas.....	144

LISTA DE SIGLAS E ABREVIATURAS

Cfa	Center for Astrophysics
CIntla	Classificador Inteligente de supernovas do tipo Ia
IEC	International Electrotechnical Commission
ISM	Interstellar Medium
KDUST	Kunlun Dark Universe Survey Telescopes
SUZAN	Sistema fUZzy Avaliador de superNovas
INPE	Instituto Nacional de Pesquisas Espaciais
GELATO	GEneric cLAssification TOol
SNID	Supernova Identification
SN	Supernova

LISTA DE SÍMBOLOS

MJ	Massa de Jeans
K	Kelvin
T	Temperatura
ρ	Densidade da nebulosa
G	Constante de força gravitacional
M	Massa
R	Raio do núcleo da protoestrela
M'	Taxa de acréscimo de massa
L	Luminosidade
Å	Angstrom, unidade de medida de comprimento de onda.
L_{\odot}	Luminosidade solar
ν	Neutrino
e^{-}	Elétron
p^{+}	Próton
n	Nêutron
$M_{estrela}$	Massa da estrela
M_{\odot}	Massas solares
$\lambda_{Supernova}$	Comprimento de onda do espectro otimizado de supernova
$\lambda_{Laboratório}$	Comprimento de onda de elementos obtidos no laboratório

SUMÁRIO

	Pág.
+ 1 INTRODUÇÃO.....	1
2 CONCEITOS FUNDAMENTAIS SOBRE SUPERNOVAS.....	9
2.1 Fundamentos da Evolução Estelar.....	9
2.1.1 Estrelas Gigantes Vermelhas e Anãs Brancas.....	15
2.2 Explosões estelares: Supernovas Termonucleares e de Colapso de Núcleo.....	18
2.2.1 Supernovas Geradas Pelo Colapso de Núcleo.....	19
2.2.2 Supernovas Termonucleares – Supernovas Ia.....	21
2.3 Implicações Cosmológicas das Supernovas Termonucleares.....	24
2.4 Classificação de Supernovas e Características Espectrais.....	27
2.4.1 Características Espectrais e Períodos de Observação.....	27
2.4.2 Características Espectrais Utilizadas na Classificação de Supernovas.....	32
2.5 Estado da Arte: Considerações sobre classificadores de supernovas Automáticos.....	43
2.5.1 Considerações sobre o classificador SNID.....	43
2.5.2 Considerações sobre o classificador GELATO.....	44
2.5.3 Considerações sobre o classificador CIntIa.....	45
3 CONCEITOS DA TEORIA DOS CONJUNTOS NEBULOSOS.....	47
3.1 Formulação Matemática dos Conjuntos Nebulosos.....	47
3.2 Representação dos Conjuntos Nebulosos.....	48
3.3 Sistemas Nebulosos.....	50
3.3.1 Variáveis Linguísticas e Normalização.....	51
3.3.2 Relações e Regras Nebulosas.....	52
3.3.3 Máquina de Inferência.....	53
3.3.4 Representação das Saídas.....	56
4 CONCEITOS SOBRE O FILTRO DE SAVITZKY-GOLAY.....	57
4.1 Fundamentos Matemáticos do Filtro Savitzky-Golay.....	57
5 ENGENHARIA DO CONHECIMENTO.....	61
5.1 Dados dos Espectros de Supernovas.....	61
5.1.1 Considerações sobre o Banco 1 de Supernovas de Tipo Ia.....	64
5.1.2 Considerações sobre o Banco 2 de Supernovas de Tipo Ia.....	65
5.1.3 Considerações sobre o Banco 3 de Supernovas de Tipo Ia.....	67
5.1.4 Considerações sobre os bancos 4,5 e 6 de Supernovas de Colapso de Núcleo.....	68
5.1.5 Considerações Sobre os Bancos de Espectros Utilizados no Desenvolvimento da CIntIa.....	70
5.2 Tratamento de dados Espectrais.....	73
5.2.1 Sistema de Filtragem Dupla pelo Filtro de Savitzky-Golay.....	74
5.2.1.1 Metodologia Utilizada na Construção do Sistema de Filtragem Dupla.....	74
5.2.1.2 Medidas de Desempenho do Sistema de Filtragem Dupla.....	78
5.2.1.3 Desempenho do Sistema de Dupla Filtragem na Aplicação de.....	78

Espectros de Supernovas.....	80
5.2.2 Ajuste de <i>Redshift</i>	93
5.2.3 Detecção de Picos e Vales no Espectro.....	94
5.2.4 Cálculo da Distância Relativa.....	95
5.2.5 Parametrização das linhas espectrais.....	96
5.2.5.1 Parâmetro de Largura Equivalente.....	98
5.2.5.2 Parâmetro de Intensidade de Pico.....	99
5.3 O Conjunto de dados Gerado Para Avaliação de Supernovas.....	100
6 DESENVOLVIMENTO DA SUZAN.....	103
6.1 Construção da Avaliação de linhas de Emissão e Absorção.....	104
6.2 Análise da Composição Química de Supernovas.....	112
7 RESULTADOS.....	121
7.1 Resultados da SUZAN para os Bancos Originais.....	124
7.2 Desempenho da SUZAN para os Bancos utilizados pelo sistema de Classificação por Redes Neurais CIntIa.....	127
7.3 Classificação de Supernovas de Tipo Ia para os Bancos 2 e 3 com Amostras Normalizadas.....	131
7.4 A Dupla Redundância para a Classificação de Supernovas do Tipo Ia pelos Sistemas SUZAN e CIntIa.....	143
8 CONCLUSÃO.....	146
8.1 Trabalhos Futuros.....	150
8.2 Publicações e Apresentações de Trabalho Realizadas Durante a Pesquisa.....	152
REFERÊNCIAS BIBLIOGRÁFICAS.....	153

1 INTRODUÇÃO

O estudo de Supernovas e a compreensão deste e de outros fenômenos referentes ao cosmos remete a uma época em que a ciência e o método científico receberam uma impulsão tanto na formação da base científica como na preservação dos registros históricos. Cientistas e astrônomos como Tycho Brahe (1546 – 1601), Galileu Galilei (1564 – 1642), Johannes Kepler (1571 – 1630), Isaac Newton (1643 – 1727), entre outros, buscaram compreender, registrar, catalogar e modelar matematicamente a dinâmica do cosmos e dos elementos que o compõe, desta forma, evidenciando e modelando as leis físicas, ainda que de maneira não completa, que regem a natureza do universo.

Ao entender como o método científico foi fundamentado é possível, com as ferramentas atuais, estabelecer uma relação entre o passado e o presente de forma a desenvolver a ciência em um caminho seguro.

Assim, foi possível a análise de um dos fenômenos astronômicos de maior importância ocorridos na antiguidade, a supernova SN 1054, hoje conhecida como nebulosa do Caranguejo. Os registros interpretados pelo astrônomo sueco Knut Lundmark (1889 – 1958), tratam de uma crônica do historiador chinês Ma Tuan-lin (1245 – 1322) que retratavam a descoberta de um astrônomo da corte chinesa, Yang Wei Te em 4 de julho de 1054 d.C. A crônica dizia o seguinte:

“No primeiro ano do período Tshiho, no quinto mês, no dia Kitschou, apareceu uma estrela desconhecida ao sudoeste de Thien-kuan. Ela deveria estar a uma distância de alguns tsun dela. No final do ano, essa estrela desapareceu” (HERRMANN, 1980).

Devido a constatações da proximidade cronológica, foi possível observar que a nebulosa do Caranguejo, descoberta pelo astrônomo inglês John Bevis (1695 – 1771), era de fato, a estrela observada pelos chineses em 1054 d.C.

Da mesma maneira, o astrônomo dinamarquês Tycho Brahe e a análise dos seus registros proporcionaram o estudo de um objeto catalogado à quase

450 anos. Este objeto é uma Supernova conhecida como SN 1572, estudada primeiramente por Tycho Brahe e atualmente objeto de estudo dos astrônomos que buscam compreender o fenômeno de maneira profunda (RUIZ-LAPUENTE et al.,2004; FUHRMANN, 2005; KRAUSE et al., 2008).

Segundo Horvath (2011), supernovas são caracterizadas como explosões de grandes proporções, ou seja, são estrelas que ao atingir os estágios finais de evolução perdem a capacidade de fusão dos núcleos e dependendo da massa original da estrela (M_{\odot} , massas solares) geram uma explosão que pode ser termonuclear ou por colapso de núcleo.

O tipo de explosão em supernovas é estritamente relacionado a estrela progenitora da supernova. Em estrelas de massa $M_{estrela} \approx 8 M_{\odot}$, o ciclo final de evolução ocorre quando a capacidade de fusão do Hélio (He) é esgotada. Desta forma, ocorrem instabilidades que ocasionam na expulsão do envoltório que constitui a estrela, este tipo de explosão não destrói a estrela por completo, pois ao final do processo resta apenas o núcleo (caroço) extremamente denso denominado anã branca (HORVATH, 2011).

Uma explosão de supernova termonuclear pode ocorrer em sistemas múltiplos, onde uma anã branca absorve a massa de uma estrela companheira, a qual pode estar no estado de gigante vermelha. Desta forma, quando a massa da anã branca atinge o limite de Chandrasekhar a estrela entra em colapso (NIEMEYER; WOOSLEY, 1997; RUITER et al.,2011). Este tipo de explosão é característico, ou seja, as condições que desencadeiam este fenômeno são similares em muitos dos casos observados. Este modelo de explosão de supernova é denominado supernova de tipo Ia.

Para estrelas com $M_{estrela} > 10 M_{\odot}$ a situação é diferente. Estrelas massivas possuem a capacidade de fusão dos elementos mais pesados, prosseguindo até o último ciclo possível de elementos, o núcleo de Fe (Ferro) (HORVATH,2011). O núcleo entra em instabilidade e depois de certo tempo o envoltório colide contra o caroço e ricocheteia, gerando uma explosão de colapso de núcleo (BURROWS; HAYES; FRYXELL, 1995). Estas explosões em estrelas massivas são denominadas supernovas de colapso de núcleo,

contemplando as nomenclaturas de supernovas de tipo Ib, Ic, II, IIb, IIP, e IIL. A formação deste fenômeno, bem como as diferentes condições que geram o colapso de estrelas massivas são bem variadas e dependem de muitos fatores (BURROWS; HAYES; FRYXELL, 1995).

Os dois tipos de explosão (termonuclear e colapso de núcleo) caracterizam as supernovas, que são dispostas em diversos esquemas de classificação que consideram as características da curva de luz e do espectro da supernova. As características fundamentais são dependentes da composição do envoltório, ou seja, da ausência ou presença de determinados elementos químicos (TURATTO; BENETTI; PASTORELLO, 2007).

A análise de curva de luz observa a evolução temporal da magnitude do brilho da explosão, esta análise é dependente de um longo período de dias. Em contrapartida, é possível analisar supernovas assim que é detectada a explosão, por meio do espectro óptico. As características espectrais referentes a elementos químicos e a formatos das linhas espectrais ficam evidentes e é possível diferenciar os tipos clássicos.

Estes tipos de análise não são triviais, e certamente a adoção de esquemas computacionais que permitam a classificação correta de cada tipo de supernova é um desafio. Para análises construídas para o espectro de supernovas os classificadores SNID (*Supernova Identification*) (BLONDIN; TONRY, 2007) e GELATO (*GEneric cLAssification TOol*) (HARUTYUNIAN, 2008), são bons exemplos. As técnicas empregadas nestes classificadores tem em sua essência o aparato estatístico e puramente algorítmico, executando correlações baseadas em modelos predefinidos de espectros de supernovas. Estes sistemas constroem um processamento prévio dos dados como o ajuste de *redshift*, filtragens e suavização de sinais, normalizações, etc. E após a normalização dos dados são empregadas as técnicas para a classificação.

Em relação a técnicas de aprendizado de máquina (*machine learning*) e inteligência artificial, o trabalho realizado por Módolo (2016) descreve o desenvolvimento de um sistema de classificação automático de estrelas

supernovas por meio do paradigma conexionista de redes neurais. A CIntla (Classificador Inteligente de supernovas do tipo Ia) possui boa performance na identificação de espectros de supernovas do tipo Ia, avaliando as principais linhas espectrais, observando os padrões de elementos presentes e inferindo os modelos básicos de supernovas a partir de dados normalizados.

Dentro deste contexto, este trabalho apresenta o desenvolvimento de um modelo para classificação automática de supernovas utilizando sistemas baseados em lógica nebulosa para a análise espectral e avaliação do espectro de supernovas. Este sistema foi denominado SUZAN, sigla para “Sistema fUZzy Avaliador de superNovas” constituindo um modelo baseado em inteligência artificial que possa avaliar o espectro óptico de uma supernova de forma semelhante a um especialista, gerando um sistema capaz de avaliar e classificar supernovas termonucleares, ou seja, supernovas de tipo Ia assim que é detectada a explosão da estrela de maneira automática e eficiente.

Em relação à modelagem computacional da classificação feita por um astrônomo, uma das formas relacionadas à representação do conhecimento é a teoria dos conjuntos nebulosos, conhecida também por Lógica Nebulosa ou Lógica Difusa (*Fuzzy Logic*), este tipo de paradigma foi apresentado por Zadeh (1965), e é amplamente aplicado a problemas de controle e diagnósticos (MÉNDEZ-GURROLA et al., 2007; RODNEY; TONRY, 2009). A teoria dos conjuntos nebulosos é estritamente relacionada a modelagem da incerteza, isto é, o trabalho com dados de caráter impreciso e vago. Por exemplo, uma pessoa pode dizer se a temperatura de determinado ambiente está agradável, fria ou muito quente, mas modelar essas informações é algo difícil, pois não existe uma restrição rígida ao que uma pessoa pode achar da temperatura de um ambiente. A lógica nebulosa trata exatamente de definir mecanismos que possam modelar esta incerteza, sem impor restrições rígidas no que se refere a informação. Desta maneira, a aplicação da lógica nebulosa para a classificação e avaliação de determinados objetos de acordo

com o conhecimento de um especialista é justificável.

A importância da identificação das supernovas termonucleares, ou seja, supernovas de tipo Ia, reside em estabelecer estas explosões como “velas padrão” (*standard candles*), ou seja, fontes de luz com intensidades bem estabelecidas. A evolução temporal da curva de luz é similar em muitas amostras, assim, supernovas de tipo Ia tornam-se importante objeto de estudo na cosmologia, fornecendo parâmetros para distâncias astronômicas e revelando avanços nos estudos relacionados a expansão cósmica (BLONDIN; MANDEL; KIRSHNER, 2011).

Outra justificativa para o desenvolvimento de classificadores automáticos de supernovas presente neste trabalho e no trabalho desenvolvido por Módolo (2016) reside na utilização destes métodos como objeto de análise e classificação de dados de supernovas relacionados ao projeto KDUST. O Projeto *Kunlun Dark Universe Survey Telescope* (KDUST) (CHINESE CENTER FOR ANTARCTIC ASTRONOMY, 2010), envolve a construção de um observatório astronômico em Kunlun, no Platô Antártico. Devido a localização, os sistemas de observação e análise devem ser automáticos. Além disto, o projeto tem por objetivo a detecção de supernovas e sua classificação logo após a explosão da estrela, para que um grande volume de informações sejam coletadas no decorrer do tempo e seja feita uma análise prolongada e específica. Neste caso, o objetivo principal é a detecção de supernovas do tipo Ia para desenvolver estudos referentes a cosmologia e a velocidade da expansão cósmica. É importante ressaltar, que as abordagens construídas nos sistemas SUZAN e Cintla para a classificação automática de supernovas Ia não se restringem apenas a aplicabilidade no projeto KDUST. O desenvolvimento destes dois trabalhos permite a integração com dados de outros telescópios e outras aplicações, neste ponto a interface computacional desenvolvida nestes trabalhos pode ser generalizada.

SUZAN e Cintla são parte de um trabalho desenvolvido no Instituto Nacional de Pesquisas Espaciais – INPE para identificação de supernovas Ia por meio

dos paradigmas de inteligência artificial, evidenciando a construção de um sistema robusto de avaliação espectral, permitindo que exista uma dupla redundância na classificação de supernovas de Tipo Ia. O objetivo deste trabalho é separar em um volume representativo de dados supernovas do tipo Ia pelo espectro. A construção destes sistemas foi executada com o suporte computacional do Instituto de Estudos Avançados – IEAv, que permitiu o uso do Laboratório Computacional de Tecnologia Nuclear da Divisão de Energia Nuclear - ENU.

A necessidade da redundância na classificação destas supernovas e a justificativa para o desenvolvimento de dois ou mais classificadores vem da aplicabilidade em um sistema que opere de maneira remota e automática em que não existe um especialista para supervisionar, interpretar ou validar as respostas destes sistemas. A análise e classificação de um grande conjunto de dados de supernovas do tipo Ia, também é um dos pontos importantes neste trabalho. Avaliar uma grande quantidade de espectros de supernovas do tipo Ia, propicia a construção de uma estatística sólida para o desenvolvimento dos estudos relacionados a cosmologia e a implicação das supernovas Ia neste contexto.

Outro ponto importante nesta pesquisa é o tratamento dos dados espectrais por técnicas em processamento de sinais digitais, neste trabalho este tipo de análise de dados foi denominada Engenharia do Conhecimento. Esta etapa foi construída para garantir dois aspectos fundamentais da construção da SUZAN: a redução de ruído e inconsistências nos dados, e o tratamento dos dados de entrada de maneira isonômica, ou seja, a garantia de que os dados de entrada sejam avaliados e normalizados de maneira homogênea e uniforme, não havendo diferenças no tratamento das entradas.

Estas inconsistências e erros inerentes aos dados brutos, quando não tratados, podem ser propagados no decorrer da análise ocasionando em uma falsa interpretação do fenômeno, pois se avalia o ruído, gerando uma tendência analítica. Batista (2003), atenta para a importância do tratamento dos dados no aprendizado de máquina supervisionado e não-supervisionado

de forma a não dimensionar a análise de um fenômeno onde nos dados existam inconsistências, erros e ruídos.

Quando um sistema necessita de uma etapa prévia para o tratamento de dados é necessário que o conhecimento do especialista esteja inserido em métodos que propiciem um processamento automático. Ou seja, a garantia de que todos os dados sejam analisados e normalizados de maneira coesa, não havendo distinções e ajustes diferentes para cada base de dados em tempos diferentes.

Desta maneira, foi desenvolvido um sistema para a normalização e tratamento dos dados de espectros de supernovas que consiste em um esquema de dupla filtragem de dados utilizando o filtro de Savitzky-Golay (SCHAFER, 2011). O filtro Savitzky-Golay, foi desenvolvido para a análise de composição química de espectros utilizando um sistema de suavização pelo método dos mínimos quadrados e interpolação polinomial mantendo as características de forma do sinal (SAVITZKY; GOLAY, 1964).

O sistema de dupla filtragem desenvolvido neste trabalho tem como propósito normalizar as entradas para o sistema SUZAN garantindo que os espectros tratados possuam:

- a) o deslocamento mínimo dos comprimentos de onda originais dos sinais;
- b) a manutenção das características de formato do sinal, garantindo a observação das características das linhas espectrais mais largas e mais estreitas.
- c) a atenuação do ruído presente nos espectros;
- d) a qualidade da busca gradiente pelos picos e vales. Esta busca propicia a análise dos picos e vales mais relevantes do sinal evitando com que o ruído seja inserido na análise.

Estas características quando combinadas permitem a geração de um conjunto de dados com a qualidade que é necessária ao analista e ao sistema. Nem sempre estas características e a combinação destes parâmetros qualitativos são possíveis. Entretanto, o sistema de dupla

filtragem proposto neste trabalho visa a otimização na construção do processamento de sinais de forma a garantir que as características citadas sejam representadas e combinadas de maneira otimizada.

Este trabalho está dividido em oito capítulos, sendo neste primeiro, tratados a justificativa, os objetivos e métodos da pesquisa.

Os princípios da evolução estelar bem como os conceitos sobre supernovas, suas características espectrais e a importância deste fenômeno no campo da cosmologia observacional são apresentados no capítulo 2. Neste mesmo capítulo é demonstrado o estado da arte, explicando de maneira sucinta alguns classificadores de supernovas pelo espectro óptico.

No capítulo 3 são apresentados os conceitos gerais referentes à lógica nebulosa e os modelos de inferência.

No capítulo 4 são demonstrados os conceitos sobre o filtro de Savitzky Golay.

No capítulo 5 são tratados os métodos utilizados para construção da etapa de engenharia do conhecimento. Este capítulo apresenta os bancos de dados utilizados nas análises estabelecidas pela SUZAN e suas peculiaridades. Este capítulo também contempla o desenvolvimento do sistema de dupla filtragem pelo filtro de Savitzky-Golay, a normalização e tratamento dos dados, além da explicação dos parâmetros utilizados na abstração das qualidades dos espectros de supernovas.

O capítulo 6 descreve as etapas de construção da SUZAN descrevendo os sistemas nebulosos para a classificação espectral de supernovas bem como a modelagem dos parâmetros espectrais utilizados.

No capítulo 7 são apresentados os resultados obtidos na performance da SUZAN, bem como uma comparação para a avaliação do sistema CIntla.

Por fim, no capítulo 8 é apresentada uma discussão dos resultados e considerações a respeito da abordagem, além da indicação para trabalhos futuros.

2 CONCEITOS FUNDAMENTAIS SOBRE SUPERNOVAS

O ciclo de vida de uma estrela é relacionado a muitos fatores que correspondem a massa inicial, composição, influências do meio, entre outros.

Primeiramente este capítulo apresenta os conceitos sobre a evolução das estrelas, do estágio inicial ao de supernova. Em seguida, são apresentadas as implicações atuais das supernovas de tipo Ia referentes a expansão cósmica. Também são explicados as características espectrais de cada tipo de supernova, evidenciando as características das supernovas de tipo Ia. Por fim são apresentados sucintamente alguns classificadores de supernovas pelo espectro.

2.1 Fundamentos da Evolução Estelar

O processo de formação das estrelas e por consequência sua evolução é considerado um problema recorrente no campo da astrofísica moderna. A modelagem deste processo é complexa e de difícil predição, pois este processo envolve uma série de fatores, por exemplo, as condições do meio interestelar (ISM), bem como as condições de temperatura, densidade, concentrações de matéria da nuvem interestelar, etc (COLLINS, 2003). Tantos elementos reduzem a precisão e a eficiência em determinar como uma estrela, ou até mesmo um sistema estelar, pode ser gerado das condições iniciais apresentadas.

A ideia inicial da formação de estrelas foi construída a partir da hipótese nebular formulada pelo filósofo alemão Immanuel Kant (1724 – 1804), e que posteriormente foi modelada por Pierre-Simon de Laplace (1749-1827) em sua obra “*Exposition du Systéme du Monde*” (HORVATH, 2008). Esta ideia tinha como fundamento as reações que ocorriam em uma nuvem de gás e poeira interestelar. Esta nuvem tornava-se coesa adquirindo velocidade de rotação (por força da atração gravitacional) e a temperatura e a pressão aumentavam no centro a ponto de gerar luminosidade. Com a evolução

científica dos estudos sobre a formação de estrelas e sistemas estelares, bem como a compreensão do processo de fusão nuclear, e com a observação dos fenômenos é possível segmentar o modelo de formação em seis etapas (POLS, 2011):

- Colapso da nuvem interestelar;
- Fragmentação da nuvem interestelar;
- Formação da Protoestrela;
- Acréscimo de matéria;
- Ionização e Dissociação;
- Pré sequência principal;
- Sequência Principal;

As estrelas são derivadas de reações nucleares que ocorrem em grandes concentrações de matéria no universo, estas concentrações de gás e poeira são compostas por diversos elementos que foram acumulados mediante a sucessivas ejeções de matéria no espaço (provindas da explosão de outras estrelas) e são denominadas nuvens interestelares (nebulosas, nebulosas primordiais, nuvens primordiais). Segundo Pols (2011), a formação estelar se inicia a partir de uma perturbação na nuvem interestelar, que pode ser causada pela explosão de uma supernova, pela colisão entre nuvens interestelares, pela união de estrelas próximas e demais colapsos que ocorrem no universo. As condições que possibilitam o equilíbrio de pressão tornam-se instáveis, principalmente pelas condições de massa que para manter o equilíbrio assumem um valor crítico, este valor é denominado massa de Jeans, que é descrita segundo a equação 2.1 (POLS, 2011).

$$MJ \approx 4 \times 10^4 M_{\odot} \left(\frac{T}{100K} \right)^{\frac{3}{2}} \left(\frac{\rho}{cm^{-3}} \right)^{-\frac{1}{2}} \quad (2.1)$$

Onde ρ é referente a densidade da nebulosa e T equivale a temperatura (Kelvin). A instabilidade ocorre para determinadas condições de temperatura

e densidade, e o valor da massa da nuvem interestelar (M_{\odot} , massas solares) passa a ser superior ao da massa de Jeans (M_J). Neste ponto, ocorre o colapso gravitacional da nuvem.

Conforme o valor de densidade da nuvem colapsante aumenta, o valor da massa de Jeans desce. O critério de estabilidade é violado e a nuvem se fragmenta em diversos pontos, em que cada qual permanece em colapso (PIERCE, 2013). O aumento da densidade nos fragmentos da nuvem colapsada torna o montante do gás opaco aos fótons infravermelhos, resultando na contenção da radiação na parte central da nuvem, levando ao aumento da temperatura e da pressão do gás. Como resultado, o núcleo da nuvem entra em equilíbrio hidrostático e o colapso dinâmico diminui a uma contração *quasi-estática*, neste ponto ocorre o nascimento de uma protoestrela.

Existe o processo de acréscimo de matéria sobre o núcleo da protoestrela, resultante do gás que circunda e se acumula formando um disco ao redor da protoestrela. Este processo ocorre de maneira parecida na maioria dos casos observados na formação de jovens estrelas. O acúmulo do gás gera energia gravitacional, promovendo o aumento da temperatura do núcleo da protoestrela, permitindo o aumento da luminosidade, conforme explica a equação 2.2.

$$L = \frac{GM M'}{2R} \quad (2.2)$$

Onde G é referente a constante de força gravitacional, M e R são correspondentes a massa e ao raio do núcleo, M' é referente a taxa de acréscimo de massa. Desta maneira, o aquecimento do núcleo da protoestrela ocorre de maneira adiabática, ou seja, o sistema mantém o aquecimento sem alterações na energia total.

O gás inicialmente composto de hidrogênio molecular comporta-se como um gás ideal e o núcleo da protoestrela permanece dinamicamente estável.

Quando a temperatura do núcleo atinge aproximadamente 2000 K o Hidrogênio molecular inicia o processo de ionização, o qual é análogo a dissociação gerando um aumento do calor específico. O equilíbrio hidrostático já não é possível e ocorre uma nova fase de colapso, durante a qual, a liberação de energia gravitacional é absorvida pelas moléculas dissociantes sem aumento significativo de temperatura. Após a ionização do Hidrogênio (H^2) e, por consequência, da produção dos núcleos de Hélio (He^4) a uma temperatura de aproximadamente 10^4 K a ionização da protoestrela está completa e o equilíbrio hidrostático é alcançado novamente em um raio reduzido.

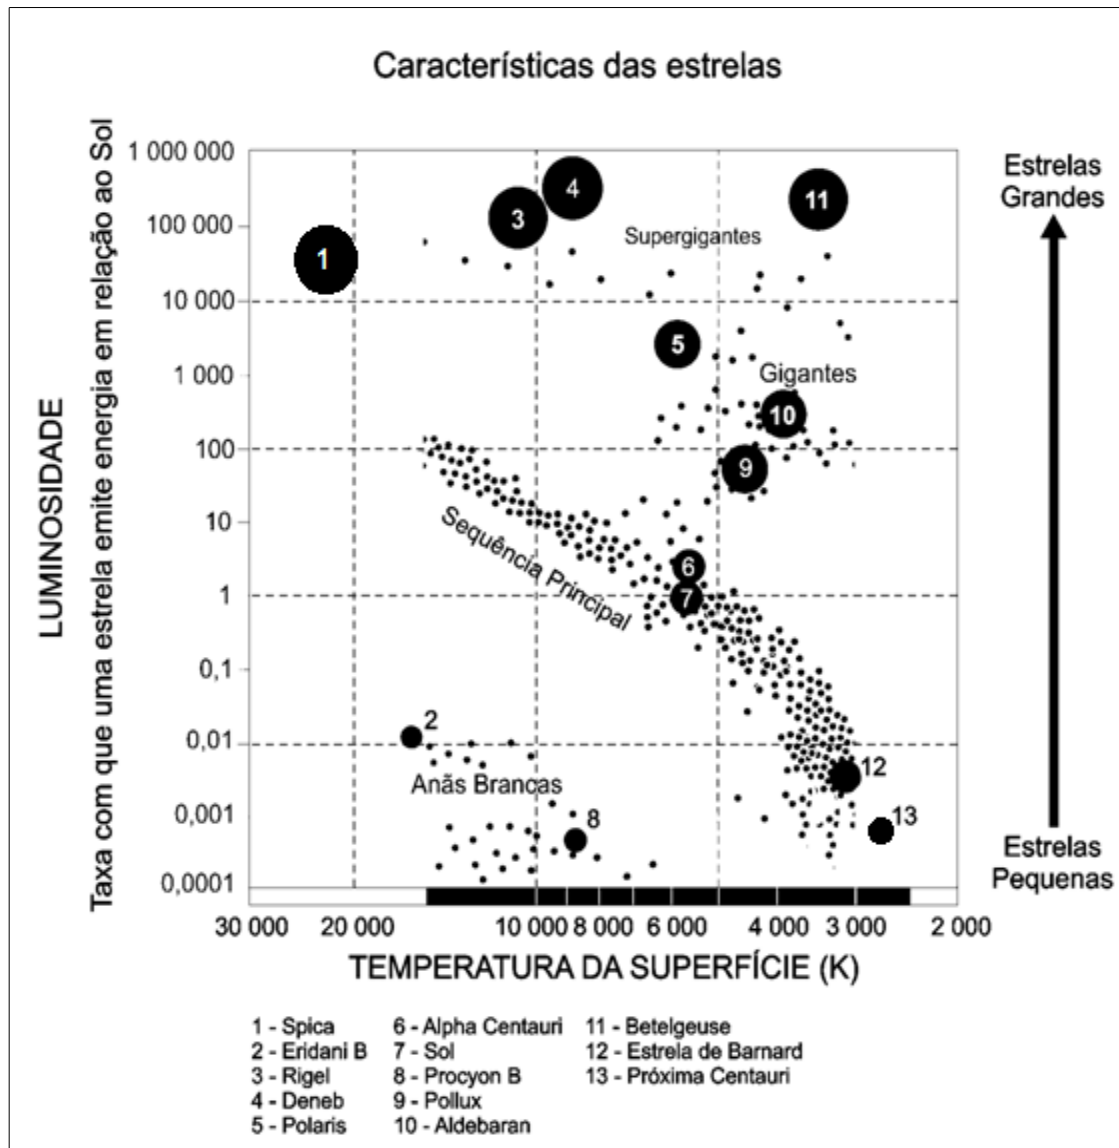
Neste ponto, o processo de acréscimo diminui gradativamente até cessar e a protoestrela atinge o estado de estrela pré sequência principal. A luminosidade é proporcionada pela contração gravitacional e a temperatura interna aumenta.

As estrelas conhecidas são primordialmente compostas de Hidrogênio e Hélio, isto se deve a composição da nuvem primordial. O processo de fusão nuclear ocorre com a ignição do Hidrogênio, garantindo energia suficiente para manter a estrela em estado de equilíbrio. Este equilíbrio é referente a força gravitacional que age sobre a estrela, comprimindo-a para o centro enquanto que a pressão gerada pelo processo de fusão termonuclear exerce o oposto. As estrelas que permanecem neste estado são consideradas como pertencentes a sequência principal.

A denominação de sequência principal, se deve, ao diagrama de Hertzsprung-Russell (Diagrama HR), que considera a relação entre a luminosidade de uma estrela e sua temperatura. Neste diagrama as estrelas que se concentram na faixa diagonal são denominadas estrelas de sequência principal, pois possuem luminosidade e temperatura maior, e isto se deve a estabilidade gerada pelo processo de fusão do Hidrogênio. Os outros pontos de concentração no diagrama são referentes a estrelas em fases de evolução diferentes, como estrelas gigantes e supergigantes vermelhas, anãs brancas e anãs vermelhas (COSMOS, 2018). A Figura 2.1

ilustra o diagrama HR para estrelas próximas, indicando as relações de temperatura e luminosidade, além das características das concentrações em diferentes regiões.

Figura 2.1 – Diagrama HR para estrelas próximas.




Fonte: Adaptado de Oliveira Filho (2011).

Os estudos de Artur Eddington (1882-1944) corroboraram para a seguinte relação: quanto maior a massa de uma estrela, maior será a atração gravitacional que ela exercerá sobre si, ou seja, quanto maior a massa de uma estrela maior será a temperatura interna necessária para manter o equilíbrio entre a força gravitacional e a pressão exercida pelo processo de

fusão. Desta maneira, estrelas com maior massa fusionam o Hidrogênio mais rápido e por isso, os processos de evolução natural ocorrem com tempo significativamente menor do que ocorre em estrelas de massa proporcional ao Sol (COLLINS, 2003; POLS, 2011; PIERCE, 2013).

As estrelas queimam Hidrogênio (como combustível) e produzem o Hélio (como cinzas), este processo de fusão ocorre até que a estrela, dependendo de sua massa, possa produzir elementos mais pesados como Carbono (C), Oxigênio (O), Neônio (Ne), Magnésio (Mg), Silício (Si) e finalmente desenvolvendo um “caroço” de Ferro (Fe), que pode ser fundido apenas por reações endotérmicas, ou seja, reações que necessitam de grandes energias para ocorrer. Esta sequência na produção de elementos ocorre em estrelas mais massivas, isto é, com massa aproximadamente $M_{estrela} > 8 M_{\odot}$. Este processo em estrelas massivas é representado por uma estrutura em camadas, a Figura 2.2 indica esta representação e os elementos que são gerados no decorrer da evolução estelar.

Figura 2.2 – Fusão dos elementos no decorrer da evolução da estrela.




Fonte: Adaptado de Horvath (2008)

2.1.1 Estrelas Gigantes Vermelhas e Anãs Brancas

A evolução estelar pós sequência principal se dá quando o Hidrogênio do núcleo é exaurido, neste ponto começa a produção do núcleo Hélio (que são as “cinzas” geradas da fusão do Hidrogênio), cercado por uma região rica em Hidrogênio que permanece inerte. Este processo interrompe o equilíbrio entre a pressão gerada pelo núcleo da estrela e a força gravitacional, ocasionando instabilidades na estrela que resultam na contração do núcleo estelar e na expansão das camadas mais externas. Esta expansão caracteriza as estrelas gigantes vermelhas, fase a qual uma estrela expande seu raio de forma a se tornar dezenas ou centenas de vezes maior do que sua estrela progenitora. O processo pós sequência principal é desenvolvido de forma diferente de acordo com a massa da estrela progenitora. Conforme citado anteriormente, o ciclo final na vida de uma supernova é caracterizado pela explosão termonuclear e de colapso de núcleo. A Figura 2.3, indica os processos que ocorrem na estrela antes que o estágio final seja atingido.

Figura 2.3 – Evolução Estelar.



Fonte: Adaptado de Anderson (2012).

Para estrelas de pouca massa, isto é, estrelas que possuem massa variando entre $M_{estrela} \approx 0.8 M_{\odot}$ e $M_{estrela} \approx 2 M_{\odot}$ a existência pós sequência principal se dá mediante o desenvolvimento de um núcleo de Hélio degenerado¹. A estrela expande as camadas externas tornando-se uma gigante vermelha, aumentando significativamente seu raio e volume em comparação a estrela progenitora, por um longo período de tempo. A ignição do Hélio desencadeia instabilidades, processo denominado *helium flash*, esta instabilidade é caracterizada como a expulsão das camadas para as redondezas, gerando muita atividade na expulsão de matéria e aumentos de luminosidade, este processo pode ocorrer muitas vezes antes que a estrela expulse todo o material e é conhecido como nebulosa planetária.

Para estrelas de massa intermediária, $M_{estrela} \approx 8 M_{\odot}$ a existência pós sequência principal se dá mediante o desenvolvimento do núcleo de Hélio não degenerado, o processo de fusão do Hélio ocorre de maneira estável. Após a fase de fusão do Hélio, é iniciada a ignição do Carbono e Oxigênio, desta forma o núcleo torna-se degenerado e as instabilidades ocorrem para a expansão em gigante vermelha.

As estrelas de baixa massa e massa intermediária expõem suas camadas externas e seus elementos são transportados para as camadas superiores pela convecção ou por difusão radiativa, e são dispersos pelo vento estelar ou ejetados para o ISM por explosões (Nebulosas Planetárias). Estas explosões e ejeção de material no ISM não destroem a estrela, pois ao final do processo resta apenas o caroço composto por Carbono e Oxigênio, denominado Anã Branca.

As estrelas anãs brancas são o produto final da evolução de estrelas de baixa massa e de massa intermediária. São estrelas compactas e de densidade elevada, com raio muito reduzido em comparação com a estrela progenitora. Para efeito de comparação as anãs brancas podem possuir um raio proporcional ao raio do planeta Terra.

¹ A matéria degenerada está relacionada ao princípio de exclusão de Pauli, que estabelece que dois férmions (elétrons, prótons e nêutrons) não podem ocupar o mesmo estado quântico simultaneamente (EISBERG; RESNICK, 1979).

Anãs brancas também são conhecidas como estrelas degeneradas, pois a pressão exercida para manter o equilíbrio, evitando o colapso gravitacional é gerada independente da temperatura, ou seja, esta pressão é originada dos estados quânticos da matéria e é denominada pressão de degenerescência dos elétrons (EISBERG; RESNICK, 1979). A partir de certa massa o colapso gravitacional vence a pressão de degenerescência e a estrutura estelar desaba. Este limite de massa é conhecido como o limite de Chandrasekhar

$M_{estrela} \approx 1.4 M_{\odot}$, este valor de massa independe da composição da estrela.

A quantidade de massa compactada em um pequeno volume eleva a densidade do objeto a tal ponto que sua atração gravitacional se torna muito forte (HORVATH, 2011).

A evolução pós sequência principal em estrelas massivas $M_{estrela} > 10 M_{\odot}$, é caracterizada pela transformação em gigante vermelha, mas com energia e massa suficiente para se desenvolver em supergigante mantendo os processos de fusão de elementos mais pesados. A ignição do Carbono e do Oxigênio ocorre em condições não degeneradas, desta maneira o processo ocorre até que o núcleo de Ferro (degenerado) seja produzido, neste ponto a estrela entra em colapso gravitacional gerando uma explosão de proporções extremas.

2.2 Explosões estelares: Supernovas Termonucleares e de Colapso de Núcleo

Supernovas são explosões cataclísmicas e catastróficas, e são parte importante da evolução estelar, pois representam o fim definitivo da vida de uma estrela. A definição de cataclismo se deve às grandes energias envolvidas no evento, as velocidades de ejeção do gás liberado para o ISM chegam a milhares de [$km \cdot s^{-1}$], e a quantidade de energia e luminosidade liberada se apresentam em ordens expressivas. A definição de catastrófica, por sua vez, é o que torna este objeto especial e raro de ser observado, supernovas não são recorrentes, pois representam a destruição total de uma estrela.

A predição das condições que engatilham este fenômeno, bem como a localização exata (regiões em determinadas galáxias) em que o fenômeno pode ocorrer, são um problema complexo no campo da astrofísica e da cosmologia, principalmente pela importância vital deste fenômeno na compreensão do comportamento do universo.

Este desfecho violento na vida de uma estrela possui certa dualidade. A explosão de uma supernova ao mesmo tempo que significa o fim da vida de uma estrela, pode engatilhar outros processos na formação de novos corpos celestes e novas estrelas. A energia gerada pela explosão de supernovas é responsável pelas reações endoenergéticas que produzem elementos mais pesados do que o Ferro.

2.2.1 Supernovas Geradas Pelo Colapso de Núcleo

As supernovas geradas pelo colapso do núcleo ocorrem em estrelas massivas de cerca de $M_{estrela} > 10 M_{\odot}$. Conforme observado anteriormente, a produção de elementos no decorrer da evolução estelar e a formação de núcleos degenerados é um fator determinante para o colapso gravitacional no núcleo estelar.

Após o ciclo do Carbono e do Oxigênio serem atingidos na evolução de estrelas massivas a fusão do Silício permite a formação de um caroço de Ferro que permanece inerte. Este núcleo de ferro é mantido pela pressão de degenerescência e quando ultrapassa o valor da massa de Chandrasekhar, entra em instabilidade exaurindo sua energia rapidamente e entrando em colapso (COLLINS, 2003; HORVATH, 2011; POLS, 2011; PIERCE, 2013).

A partir da formação do núcleo de Ferro a altíssimas temperaturas são produzidas duas partículas sem massa, os fótons e os neutrinos [ν]. A formação dos neutrinos se deve ao processo de combinação dos elétrons com os prótons descrito pela equação 2.3, que geram um nêutron e um neutrino.




Os fótons interagem com a matéria de maneira muito evidente, estas partículas demoram para percorrer a distância do núcleo estelar até superfície de onde escapam e se irradiam para o ISM, desta maneira a exaustão da energia central pelos fótons é muito pequena.

Os neutrinos, por sua vez, escapam de maneira mais rápida do núcleo estelar por possuírem fraca interação com a matéria, e desta forma toda a energia emitida na forma de neutrinos se perde quase que no mesmo instante. No decorrer da evolução das estrelas massivas os neutrinos são produzidos em grandes escalas e escapam rapidamente do núcleo, exaurindo o núcleo da energia necessária para manter a estrela em estado

de equilíbrio em relação a força gravitacional, desta maneira o envelope (camadas externas ao núcleo) desaba sobre o núcleo que ricocheteia para fora gerando uma explosão que libera grandes quantidades de energia que expulsam o material estelar a grandes velocidades. A Figura 2.4 ilustra os processos que ocorrem para o colapso do núcleo de estrelas massivas (COLLINS, 2003; HORVATH, 2011; POLS, 2011; PIERCE, 2013).

Figura 2.4 – Esquema do colapso de núcleo em estrelas massivas.



Onde (a) representa a nucleossíntese das estrelas massivas, (b) é o núcleo de ferro atingindo o limite de massa, (c) representa a parte interna do núcleo estelar comprimida e perdendo energia pela produção de neutrinos, (d) representa a instabilidade gerada no equilíbrio da pressão, (e) representa o desabamento das camadas exteriores sobre o núcleo e (f) representa a expulsão das camadas externas que foram rebatidas pelo núcleo.

Fonte: Adaptado de Oliveira Filho (2011).

Após a explosão o núcleo se contrai em um volume muito pequeno (aproximadamente cerca de dezenas de quilômetros de raio), isto eleva a densidade do objeto, formando uma estrela de nêutrons, este processo também é dependente da massa da estrela progenitora, pois em estrelas de massa aproximada $M_{estrela} \gg 20 M_{\odot}$ é possível o desenvolvimento de um buraco negro.

O processo Urca, que explica o colapso de núcleo em estrelas para formação de supernovas, foi uma contribuição dos físicos George Gamow (1904 –

1968) e Mário Schenberg (1914 – 1990). O brasileiro Mário Schenberg observou que os estudos de Gamow em relação ao colapso do núcleo de estrelas massivas não levava em consideração os neutrinos, e constatou que a emissão destas partículas era responsável pela exaustão da energia do núcleo de ferro e que desta forma reduzia a pressão necessária para manter o equilíbrio, gerando o colapso gravitacional (GAMOW; SCHENBERG, 1941).

2.2.2 Supernovas Termonucleares – Supernovas Ia

Supernovas termonucleares são derivadas das reações que ocorrem quando uma estrela em estado de anã branca recebe um acréscimo de massa, desencadeando reações termonucleares até atingir um estado crítico e colapsar. Os colapsos em estrelas gerados desta maneira são denominadas supernovas de tipo Ia.

O acréscimo de matéria de anã branca pode ocorrer em um sistema binário em que uma estrela em estado de gigante vermelha orbita uma outra em estado de anã branca, a interação entre os corpos celestes permite o acréscimo de massa na anã branca (principalmente pela força gravitacional exercida pelo objeto extremamente denso) e o início de um ciclo de detonações termonucleares na superfície da anã branca. Este processo de acréscimo de massa pode ocorrer também em interações de anãs brancas e estrelas companheiras na sequência principal.

A estrela degenerada ganha massa a ponto de ultrapassar o limite de Chandrasekhar de $M_{estrela} > 1.4 M_{\odot}$. Quando este limite é atingido o equilíbrio entre a pressão de degenerescência e a força gravitacional não é possível e ocorre o colapso gravitacional.

O processo de acréscimo de massa permanece incerto, havendo uma inclinação para que a ideia de sistemas binários de anãs brancas e estrelas em estado de gigante vermelha seja estabelecida. Bramante (2015) observou que determinada estrela anã branca absorveu massa de maneira a desencadear reações termonucleares, mas em sistemas sem a presença de estrelas companheiras. O artigo proposto "*Dark matter ignition of type Ia*


supernovae” indica que estrelas supernovas Ia podem explodir antes de atingir o limite de Chandrasekhar e em alguns casos absorver matéria de maneiras desconhecidas, como a absorção de matéria escura (BRAMANTE, 2015).

Outro ponto importante é que ainda foram constatadas a formação de supernovas termonucleares em sistemas múltiplos com a presença de estrelas anãs brancas que orbitam entre si, a colisão entre os corpos gera o acréscimo de massa e ocorre o colapso das estrelas. Neste sentido é válida a ressalva de que todos os elementos que compõem a formação deste modelo de supernova ainda não foram completamente definidos ou constados, tornando este fenômeno ainda mais complexo (COLGATE, 1971; NOMOTO; THIELEMANN; YOKOI, 1984; UMEDA et al. 1999; SULLIVAN et al. 2006).

Para supernovas que se formam desta maneira o fim é definitivo, ou seja, não foram observados ou estudados indícios que indicam o remanescente da explosão, como é o caso de supernovas que ocorrem em estrelas massivas. As figuras 2.5 e 2.6 revelam uma representação artística da formação de supernovas Ia, indicando os processos de acréscimo de massa e interação em sistemas estelares múltiplos, compostos por duas relações:

- sistemas formados por gigantes vermelhas e anãs brancas e
- sistemas formados por múltiplas anãs brancas.


Figura 2.5 – Esquema para formação de supernovas Ia para sistemas binários compostos por anãs brancas e gigantes vermelhas.



Onde (a) é a interação entre a estrela gigante vermelha e a anã branca, (b) é o acréscimo de massa provindo da absorção do Hidrogênio da gigante vermelha pela anã branca depositando-se no disco de acreção, (c) representa a anã branca atingindo o limite de Chandrasekhar e entrando em colapso para a detonação da supernova Ia.

Fonte: Adaptado de Villar (2015).

Figura 2.6 – Esquema para formação de supernovas Ia para sistemas binários compostos por anãs brancas.



Onde (a) é a interação entre estrelas anãs brancas, (b) é o processo de colisão entre as anãs brancas gerando energia suficiente para que exista uma detonação termonuclear nas estrelas (c) representa as anãs brancas atingindo o limite de Chandrasekhar e entrando em colapso para a detonação da supernova tipo Ia.

Fonte: Adaptado de Villar (2015).

A interação entre anãs brancas, ilustradas na Figura 2.6, indica a emissão de ondas gravitacionais, sendo o resultante da interação entre os corpos para o acréscimo de massa. Ondas gravitacionais são uma perturbação no tecido espaço-tempo que ocorrem mediante um evento cataclísmico. Esta perturbação no espaço-tempo foi teorizada por Albert Einstein (1879 – 1955) englobando as definições da teoria da relatividade. O Instituto Nacional de Pesquisas Espaciais teve um papel importante para a confirmação desta teoria, que foi a detecção das ondas gravitacionais geradas pela fusão de buracos negros pelo observatório LIGO (*Laser Interferometer Gravitational-wave Observatory*) (ABBOTT, 2016). Sob a direção e supervisão do pesquisador titular do INPE Odylio Aguiar, os pesquisadores brasileiros que participaram da colaboração INPE/LIGO foram, Marcos André Okada, César Augusto Costa, Márcio Constâncio Jr., Elvis Camilo Ferreira e Allan Douglas dos Santos Silva. Esta colaboração rendeu o Prêmio Nobel de Física de 2017 para os cientistas Rainer Weiss, Barry Barish e Kip Thorne.

2.3 Implicações Cosmológicas das Supernovas Termonucleares


As implicações cosmológicas a respeito das supernovas são referentes a modelos de análise que tratam da taxa a qual se expande o Universo. Não só o universo está se expandindo mas esta expansão ocorre em ritmo acelerado. Esta constatação é proveniente dos estudos de dois grupos de pesquisas principais, que resultaram no Premio Nobel de Física de 2011 para o astrônomo Saul Perlmutter (PERLMUTTER et al., 1999), e os astrônomos Adam G. Riess e Brian P. Schmidt (RIESS et al., 1998) que identificaram as características marcantes do brilho das supernovas do tipo Ia.

As supernovas de tipo Ia, como mencionadas na seção anterior tem em sua formação o colapso de uma estrela anã branca. Desta forma, o fenômeno ocorre para estrelas de massa e composição similares, gerando desta maneira um fenômeno bem estabelecido, e que embora as condições de formação e explosão ainda não sejam totalmente definitivas apresentam-se de maneira similar.

A utilização das supernovas de tipo Ia em estudos cosmológicos se baseia na análise da curva de luz, ou seja, a análise da evolução temporal da luminosidade da explosão.

As curvas de luz geradas por explosões de supernovas Ia são similares, tornando este objeto em uma vela-padrão. A curva de luz apresenta um máximo seguido de um decaimento exponencial de curta duração e depois um outro decaimento de duração mais longa. Estes decaimentos na luminosidade são efeitos da produção de elementos pesados como o Cobalto, Níquel e o Ferro. A Figura 2.7 ilustra as curvas de luz de supernovas de tipo Ia e depois o ajuste de escalas e variações para indicar a similaridade dos eventos (ARNETT, 1982; HÖFLICH; KHOKHLOV, 1996).

Figura 2.7 – Curvas de Luz de supernovas de Tipo Ia



Fonte: Adaptado de Whittle (2018).

Segundo Horvath et al. (2011), uma supernova de tipo Ia em uma galáxia distante fornece um método para o cálculo das distâncias, a análise da curva de luz estabelece dados para o cálculo da magnitude aparente e desta forma obtém-se o módulo de distância em relação a luminosidade. A equação 2.4 indica a relação fundamental utilizada pelos astrônomos para o cálculo das distâncias astronômicas pela magnitude aparente (m) das estrelas, esta equação é descrita no livro: “Cosmologia Física do Micro ao Macro Cosmos e Vice-Versa” (Horvath et al. 2011).

$$m = M - 5 \log h + 42,38 + 5 \log r(z) \quad (2.4)$$

Onde h é a constante de Hubble em unidades de 70 Km/s/Mpc, o coeficiente na adição é referente a conversão de unidades. A variável M é referente a magnitude absoluta do objeto. A variável z é referente ao *redshift* da galáxia hospedeira, este *redshift* é calculado mediante a movimentação das linhas de emissão e absorção do espectro da galáxia hospedeira.

O estudo das supernovas Ia em galáxias distantes, ou seja, com *redshifts* elevados é complexo, principalmente pela necessidade de identificar estes tipos logo após a explosão da estrela. Neste caso só é possível a análise

pelo espectro da supernova na banda espectral do óptico logo após a explosão da estrela, onde as características de elementos como o Silício e o Enxofre estão evidentes em regiões específicas do espectro.

Pesquisadores vem coletando espectros de supernovas com uma grande variedade de telescópios diferentes desde 1998, de forma a classificar supernovas logo após seu aparecimento (BLONDIN; MANDEL; KIRSHNER, 2011; BLONDIN et al., 2012; MODJAZ et al., 2014). Os dados indicam muitas variações nas escalas, principalmente por tratar de variados instrumentos.

No Brasil, o Instituto Nacional de Pesquisas Espaciais iniciou estudos referentes a identificação e classificação de supernovas la pelo espectro óptico por técnicas de inteligência artificial, a fim de identificar supernovas de maneira automática sem a interferência de um especialista para analisar os espectros, de forma a desenvolver sistemas que operem de maneira remota. Um dos trabalhos foi desenvolvido por Módolo (2016) com o classificador baseado em redes neurais artificias CIntla.

O trabalho apresentado nesta dissertação também trata da classificação de supernovas do tipo Ia sobre um grande conjunto de dados de forma a classificar as supernovas estabelecendo uma análise qualitativa dos dados, identificando as nuances que se apresentam nas bases de dados e que foram identificadas no decorrer do desenvolvimento, de forma a contribuir para as pesquisas derivadas das medições de distâncias cosmológicas e da expansão acelerada do Universo.

2.4 Classificação de Supernovas e Características Espectrais

Supernovas possuem tipos distintos e são classificadas tanto pela composição química como pelo tipo de explosão. As supernovas são derivadas em dois grupos, supernovas do tipo I e do tipo II, que possuem também subcategorias: Ia, Ib, Ic, IIb, IIL, IIP e IIn, terminologia que foi inicialmente constituída pelos estudos de Walter Baade (1893 – 1960) e Fritz Zwicky(1898 – 1974) em 1934 (BAADE; ZWICKY, 1934). Cada tipo de supernova possui peculiaridades referentes a sua composição química e formas de evolução. As próximas subseções indicam algumas das características dos espectros estudados neste trabalho.

2.4.1 Características Espectrais e Períodos de Observação


A análise do espectro é definida segundo as Leis de Kirchhoff para a espectroscopia. Nos itens seguintes, estas leis são definidas de maneira sucinta (EISBERG; RESNICK, 1979):

- I. seja uma fonte opaca de alta temperatura, a qual pode ser um sólido, liquido ou um gás em alta pressão, a radiação é emitida em todos os comprimentos de onda. Caracteriza o **espectro contínuo** (Linha contínua);
- II. seja uma fonte de alta temperatura, a qual pode ser um gás a baixa pressão, o espectro de radiação desta fonte emite luz em determinados comprimentos de onda, ou seja, são linhas brilhantes em um fundo escuro. Caracteriza o **espectro de emissão** (Linha de Emissão);
- III. seja uma fonte de alta temperatura, quando a radiação atravessa um gás mais frio, o espectro de radiação emite luz em todos os comprimentos de onda exceto em certas posições onde a intensidade é diminuta. Caracteriza o **espectro de absorção** (Linha de Absorção);

As características e a posição das linhas espectrais são determinadas pelos elementos químicos que compõem a fonte.

Este trabalho abstrai dos dados espectrais as informações das linhas de emissão e de absorção, permitindo que a classificação das supernovas seja construída pela análise da composição química do espectro. Um espectro pode ser caracterizado como um gráfico em que existe a relação entre o fluxo de radiação em função do comprimento de onda observado. Nesta representação, os vales contidos são representações das linhas de absorção, enquanto que os picos são referentes às linhas de emissão. A Figura 2.8 ilustra o espectro da supernova de tipo Ia, SN 1994D no seu ponto de brilho máximo, com a fase espectral igual a 0.


Figura 2.8 – Supernova 1994D de Tipo Ia na fase de Brilho Máximo



Fonte: Produção do Autor.

Neste trabalho, as definições de fase de brilho máximo e de fases nebulares são importantes para identificação das características de cada espectro no decorrer de sua evolução temporal. Assim como observado na análise da curva de luz de supernovas, quando a luminosidade da explosão atinge seu pico máximo é definido o conceito de brilho máximo. A Figura 2.9 indica um exemplo de curva de luz computada para observação de 22 supernovas de tipo Ia no decorrer do tempo.


Figura 2.9 – Curva de luz de supernovas Ia



Fonte: Adaptado de Branch e Tammann (1992).

A análise da curva de luz permite a abstração de um parâmetro que é inserido nos espectros. Este parâmetro é denominado fase espectral que define os dias anteriores e posteriores ao pico de luminosidade máxima da curva de luz. Desta maneira, os espectros observados continuamente recebem o parâmetro de fase espectral para definir sua proximidade ao pico máximo de luminosidade da curva de luz da supernova. A Figura 2.10 indica o espectro da supernova de tipo Ia SN 1998aq e suas respectivas fases espectrais em relação ao brilho máximo, indicando cada um dos perfis diferentes em relação a determinada fase de observação.

Figura 2.10 – Fases espectrais da supernova SN 1998aq



Fonte: Adaptado de Blondin et al (2012).

As fases espectrais definidas como 0 são referentes ao espectro observado no ponto em que a curva de luz atinge seu máximo. Por exemplo, fases espectrais com valores de -5 em relação ao brilho máximo definem um espectro observado cinco dias antes da curva de luz atingir seu ponto de máximo. Fases espectrais com valores de +5 definem um espectro observado cinco dias após a curva de luz atingir seu ponto de brilho máximo. Os espectros definidos como estando na fase de brilho máximo, são espectros observados em períodos próximos a luminosidade máxima da


2.4.2 Características Espectrais Utilizadas na Classificação de Supernovas

As supernovas do Tipo I se caracterizam por não possuir linhas de Hidrogênio em seu espectro óptico tanto em emissão como em absorção, em contrapartida as supernovas do Tipo II possuem Hidrogênio tanto em emissão como em absorção.

Supernovas de Tipo Ia possuem linhas espectrais geradas pela presença de metais pesados. Os tipos de supernovas Ib e Ic possuem a presença de linhas espectrais dominadas por elementos de massa intermediária, estes tipos de supernova resultam da explosão de estrelas massivas que expõem seus envelopes (envoltórios, camadas superiores) antes de explodir.

As supernovas de tipo Ib expõem o seu envoltório de Hidrogênio antes da explosão enquanto que supernovas de tipo Ic expõem o envoltório de Hélio. Portanto, supernovas de tipo Ib possuem forte emissão e absorção de linhas de He no espectro óptico, além de elementos como O e Ca (FILIPPENKO,1997). A Figura 2.12 ilustra a supernova SN 1995F de tipo Ib na fase de brilho máximo.


Figura 2.12 – Supernova 1995F de Tipo Ib na fase de Brilho Máximo



Fonte: Produção do Autor.


As supernovas Ib e Ic possuem propriedades similares às supernovas de tipo II, pois a estrela progenitora é considerada uma estrela massiva, entretanto estas supernovas não possuem as linhas de Hidrogênio pois expeliram a camada do elemento antes de explodir. As figuras 2.13 e 2.14 indicam espectros de supernovas de tipo Ic na sua fase de brilho máximo. As supernovas SN 2005az e a supernova SN 2007ce foram separadas para indicar a diferença entre espectros deste tipo mesmo estando na mesma fase de observação. Como citado anteriormente, supernovas de colapso de núcleo são classificadas por não possuírem determinadas linhas de elementos, principalmente, metais pesados. Entretanto, os padrões e perfis diferem de caso para caso, isto se deve às condições de formação do fenômeno, que por mais que sejam o resultado do colapso de estrelas massivas, as variáveis que compreendem sua formação ainda não foram totalmente exploradas. Tais diferenças e peculiaridades podem ser determinadas pela análise espectral, principalmente durante o período de poucos dias após a explosão da estrela, ou seja, seu período de brilho máximo.

Figura 2.13 – Supernova 2005az de Tipo Ic na fase de Brilho Máximo



Fonte: Produção do Autor.


Figura 2.14 – Supernova 2007ce de Tipo Ic na fase de Brilho Máximo



Fonte: Produção do Autor.

A Figura 2.15 ilustra a comparação das supernovas do tipo Ic na mesma fase de observação, de forma a reforçar as peculiaridades existentes no mesmo tipo de supernova. As linhas realçadas como grandes picos, ou seja, grandes emissões, neste espectro são características marcantes de raios cósmicos.


Figura 2.15 – Comparação das Supernovas Ic 2005az e 2007ce na fase de Brilho Máximo



Fonte: Produção do Autor.

Supernovas de tipo II são caracterizadas por possuir, em seu espectro óptico, linhas largas e estreitas de Hidrogênio, relacionadas às linhas da série de Balmer e Lyman e são resultado da explosão de estrelas massivas (FILIPPENKO,1997; BRANCH et al., 2003). A Figura 2.16 ilustra o exemplo da supernova SN 2008bo de tipo II na sua fase de brilho máximo.

Figura 2.16 – Supernova 2008bo de Tipo II na fase de Brilho Máximo




Fonte: Produção do Autor.

Supernovas de tipo Ia possuem sua composição e modelo de formação bem definidos, pois são o colapso de anãs brancas. O tipo Ia exibe alta absorção nas regiões do Silício neutro e uma vez ionizado (Si I e Si II), devido as condições de formação do fenômeno. Neste tipo também incidem a absorção de Enxofre neutro e uma vez ionizado (S I e S II), e a emissão de linhas de Ferro (Fe I), produzindo linhas largas de emissão e absorção devido as grandes velocidades do gás expelido. Nas regiões espectrais do Infravermelho este tipo também apresenta um decaimento no fluxo de radiação caracterizado como uma linha em declínio como é mostrado na Figura 2.8 (FILIPPENKO,1997; BRANCH et al., 2003).

No esquema de classificação proposto por Turatto (2003), supernovas do tipo

Ia são relacionadas a explosão termonuclear, enquanto que os outros tipos (Ib,Ic,II,IIb,II-n) são relacionadas a explosão por colapso de núcleo de estrelas massivas. A Figura 2.17 ilustra o esquema de classificação baseado na ausência ou presença de determinadas linhas espectrais.

Figura 2.17 – Esquema de classificação de Turatto.




Fonte: Adaptado de Turatto (2003).

O modelo de classificação proposto neste trabalho se baseia nas regras geradas pelo esquema de classificação de Turatto (2003), que contempla a classificação de diversos tipos de supernovas considerando as peculiaridades envolvidas no espectro óptico em relação a seus elementos. Neste esquema são consideradas as características de supernovas em um período próximo do brilho máximo, é neste período que os astrônomos identificam com facilidade os tipos clássicos de supernova de acordo com sua composição química. Neste ponto de evolução as características espectrais estão bem definidas e é possível reconhecer as linhas de emissão e absorção que representam os elementos-chave de composição.

A Figura 2.18 ilustra algumas das características do espectro óptico de cada um dos tipos de supernovas (Ia,Ib,Ic,Ic-bl e IIb) e a peculiaridade de cada tipo relacionada às linhas de emissão e absorção no período de brilho máximo.

Figura 2.18 – Características espectrais dos tipos clássicos de supernovas no período de brilho máximo.



Fonte: Adaptado de Modjaz (2014).

As características do fenômeno relacionadas às análises espectrais, demonstram que as grandes energias e velocidades envolvidas nas explosões deformam os espectros, evidenciando largas linhas em emissão e absorção para determinados tipos de supernovas. Em outros casos, demonstram linhas estreitas em emissão e absorção, a este tipo de situação são inseridas as nomenclaturas: **b** (*Broad Lines*) para linhas largas e **n** (*Narrow Lines*) para linhas estreitas.

Existe a necessidade da determinação do *redshift* da galáxia hospedeira para analisar o objeto como se ele estivesse em repouso, determinando assim a proximidade com linhas espectrais de elementos obtidas em laboratório. Este ajuste de *redshift* é relacionado ao efeito Doppler (SLOAN DIGITAL SKY SURVEY, 2017).

Estes espectros possuem uma dependência temporal, ou seja, evoluem no decorrer do tempo modificando suas características morfológicas e os comprimentos de onda do sinal, assim como é observado na análise contínua da curva de luz das supernovas. Desta forma, a classificação do fenômeno torna-se algo difícil, principalmente pelas diferentes interpretações que podem ser feitas do mesmo espectro.

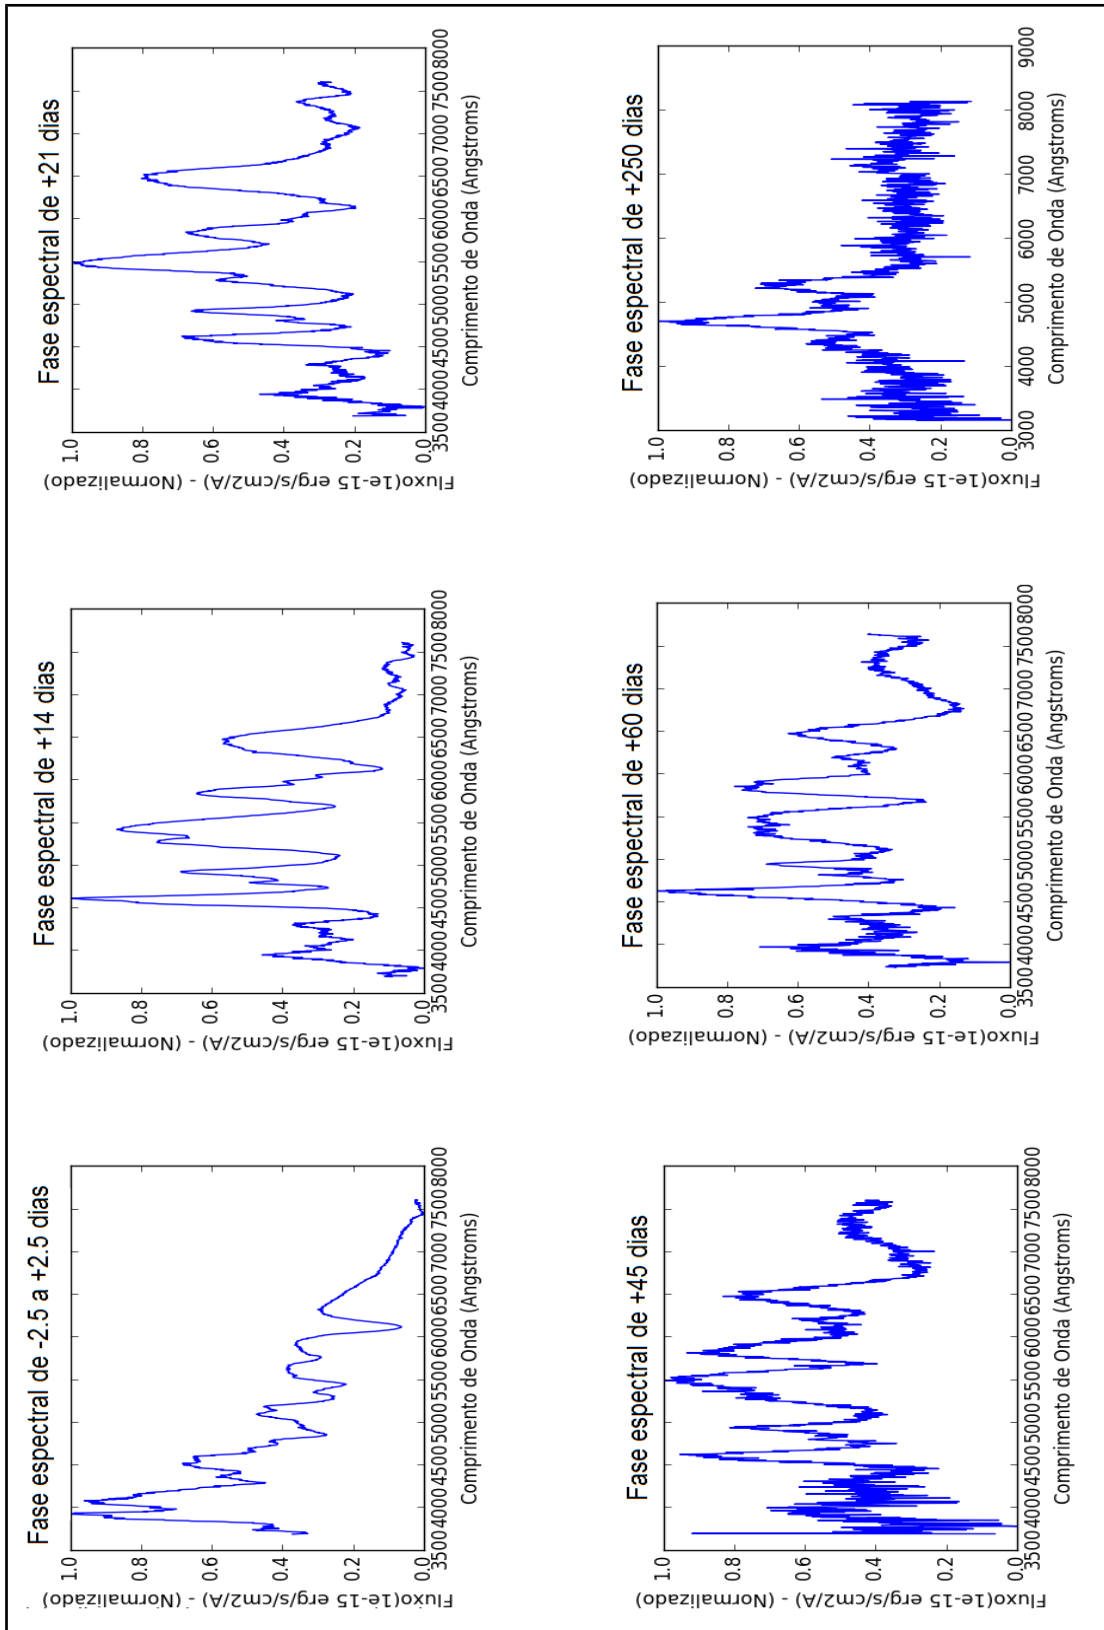
As condições de classificação, a análise dos componentes químicos da

atmosfera estelar e a observação da composição do gás ejetado podem ser prejudicadas quando além das modificações do sinal, que são inerentes a natureza do fenômeno, exista o ruído ou interferência provinda do aparelho de coleta de dados ou de condições externas.

A Figura 2.19, ilustra a modificação da supernova SN 1994D no decorrer de alguns dias, semanas e meses em relação ao período de brilho máximo que é calculado mediante a análise da curva de luz. A fase *pré-nebular* se dá no decorrer de duas semanas a um mês em relação ao brilho máximo, enquanto que a fase nebular é observada em um período maior de meses. Cada uma destas fases demonstram linhas de elementos diferentes, tornando a classificação ainda mais complexa.

Os espectros da supernova 1994D foram capturados pelo mesmo instrumento FLWO 1.5m+FAST. As fases destas supernovas são referentes aos padrões e perfis dos espectros no decorrer dos dias. A fase indicada no período de -2.5 a +2.5 dias é referente ao perfil de supernova Ia na sua fase de brilho máximo, por estar próxima ao pico de luminosidade da curva de luz. As fases de +14 dias, +21 dias, +45 dias são referentes a transformação do espectro em uma fase *pré-nebular*. Nas fases acima de +60 dias, os espectros são estabelecidos como supernovas nas fases nebulares. As características destes espectros, bem como a identificação de seus elementos são peculiares para cada período de observação.

Figura 2.19 – Evolução Temporal do Espectro da Supernova SN 1994D.



Fonte: Produção do Autor.

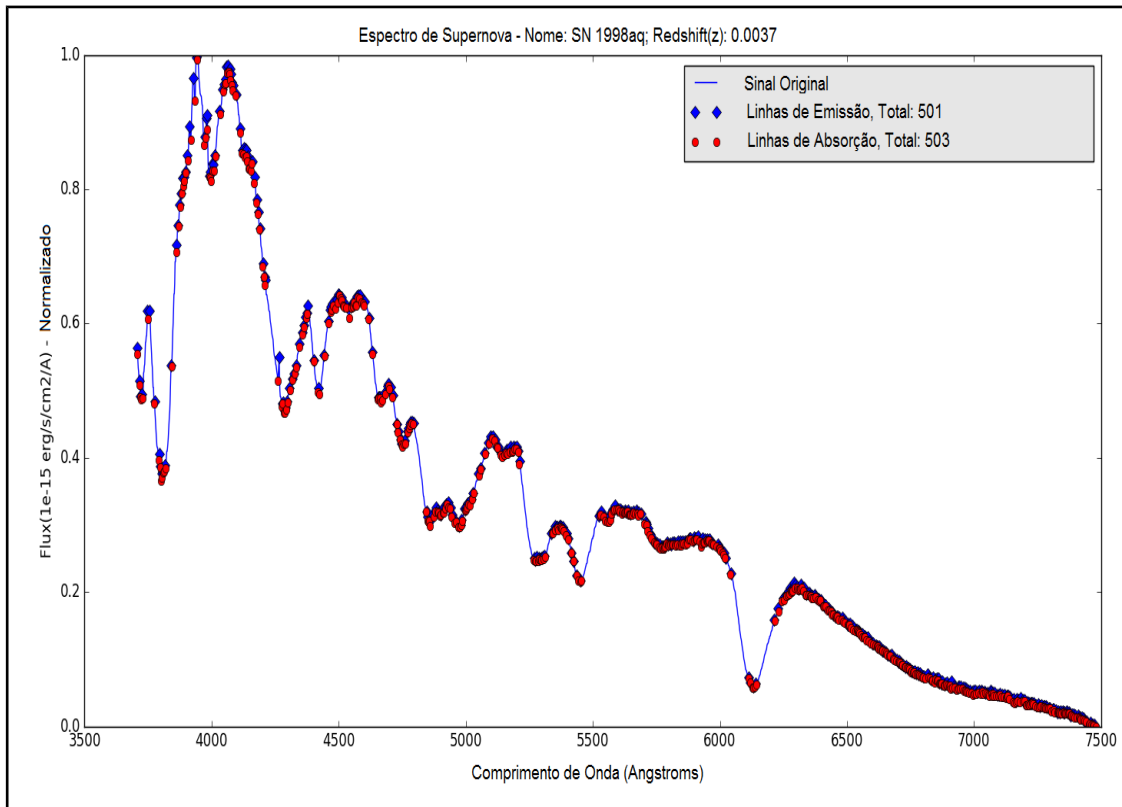
A captura do sinal do espectro óptico permite que o especialista, em um curto período de tempo, observe as características da supernova e possa classificá-la. Este tipo de análise permite uma avaliação logo após a explosão da estrela. Para a análise de supernovas por curvas de luz é necessário um período de tempo maior, em que as características de decaimento radioativo dos elementos que compõe a estrela são observadas.

Em supernovas do tipo Ia, são observados em um período de 45 a 60 dias o decaimento do Co^{56} que modifica o formato da curva de luz, este decaimento ocorre de maneira sequencial do início ao fim da explosão das supernovas termonucleares e é descrito pela equação 2.5, esta característica produz as similaridades nas curvas de luz observadas.



Em relação a análise espectral, um especialista pode selecionar apenas as linhas espectrais importantes, desprezando os picos e vales que não podem ser avaliados ou que estejam caracterizados como um ruído. Em contrapartida, esta avaliação se torna difícil para um sistema automático sem que exista o tratamento do sinal. A Figura 2.20 ilustra uma busca de gradientes feita para a supernova de tipo Ia, SN 1998aq, com o *redshift* a 0.0037 no período de brilho máximo, a imagem também indica a quantidade de picos e vales encontrados no sinal por um sistema de busca simples, sem que exista o tratamento do sinal. O sinal possui o fluxo normalizado em valores de 0 a 1.

Figura 2.20 – Busca de gradientes para SN 1998aq



Fonte: Produção do Autor.

É evidente que uma análise para este espectro torna-se deficiente pela grande quantidade de picos e vales presentes, contabilizando um total de 1004 linhas espectrais encontradas. A abstração de parâmetros como as larguras equivalentes de cada pico e vale, bem como o cálculo de intensidade de pico não revelam a realidade do fenômeno, pois desta forma é avaliado o ruído presente na amostra.

2.5 Estado da Arte: Considerações sobre classificadores de supernovas Automáticos

Esta seção tem como objetivo indicar os trabalhos correlatos a pesquisa apresentada nesta dissertação. Os classificadores têm sua essência voltada a classificação espectral, avaliando espectros de diversos tipos de supernovas. As técnicas empregadas no desenvolvimento destes classificadores são baseadas tanto em técnicas de *machine learning* como em técnicas de matemática e estatística para execução de correlações de similaridade. As próximas subseções indicam as características e considerações sobre cada classificador pesquisado.

2.5.1 Considerações sobre o classificador SNID

O classificador SNID (Supernovae Identification), foi desenvolvido por Blondin e Tonry (2007), e possui em sua essência o aparato estatístico de correlação de similaridades. Este classificador de supernovas engloba não só a classificação de tipo de supernova como tenta aproximar uma correlação completa de idade, ou seja, o tempo da explosão de supernova e o redshift para relacionar com os estudos de cosmologia.

O classificador SNID tenta aproximar uma análise completa e revela a importância de não somente identificar tipos básicos, gerando uma análise completa referente a idade e ao redshift, para identificar supernovas mesmo que o seu espectro seja colhido muitos dias depois, ou muitos dias antes da supernova atingir o pico de luminosidade máxima.

Um ponto importante nesta análise é que a classificação só é válida se os espectros modelos de entrada para a correlação são conhecidos. Por exemplo, na classificação de supernovas Ia, só serão válidos os espectros similares ao modelo clássico de supernovas, qualquer variação neste tipo modifica o resultado da classificação, desta forma o classificador pode descartar supernovas Ia por não se parecerem com os modelos previamente definidos.

Outro ponto observado, é a necessidade de se verificar o redshift da supernova antes da classificação, pois é com o redshift da supernova que é possível correlacionar com os modelos de supernovas a determinado redshift.

Como resultados desta análise foram avaliados 879 espectros de 65 supernovas de tipo Ia, 322 espectros de 19 supernovas de tipo Ib e Ic, e 353 espectros de 10 supernovas de tipo II.

2.5.2 Considerações sobre o classificador GELATO

O classificador GETATO (*GEneric cLAssification Tool*), foi desenvolvido por Harutyunian (2008), e assim como o SNID possui em sua essência o aparato estatístico meramente algorítmico.

O classificador GELATO executa uma série de normalizações e suavizações nos espectros de supernovas para realizar a classificação por similaridades. Neste classificador existe um banco de espectros com os principais tipos de supernovas, a partir dos modelos guardados nos bancos dados, novos espectros de entrada são combinados com os modelos e os que possuem maior similaridade com os modelos são classificados de acordo com o tipo de modelo.

Este classificador faz a divisão dos espectros de supernova em 11 intervalos do comprimento de onda, a comparação com os modelos de supernovas é feito em cada um destes intervalos.

O modelo de processamento de dados espectrais deste trabalho não é totalmente automático pois para determinados espectros os parâmetros de suavização e remoção de ruídos foram diferentes e foram escolhidos de acordo com o desenvolvedor da ferramenta. Além disso para determinados intervalos no espectro existiam suavizações diferentes, neste caso um tratamento automático seguro não pode acontecer sem a presença do especialista para ajustes manuais.

2.5.3 Considerações sobre o classificador CIntla

O classificador CIntla (Classificador Inteligente de Supernovas Ia) desenvolvido por Módolo (2016), é parte, assim como a pesquisa apresentada nesta dissertação, de um trabalho do Instituto Nacional de Pesquisas Espaciais no âmbito da pós-graduação em Computação Aplicada para a classificação de supernovas de tipo Ia em integração com sistemas automáticos baseados em técnicas de *machine learning* e inteligência artificial.

Este classificador avalia cerca de 559 espectros de 192 supernovas de tipo Ia, 33 espectros de 12 supernovas de tipo Ib, 44 espectros de 12 supernovas de tipo Ic e 13 espectros de 5 supernovas de tipo II.

Estes espectros passam por uma etapa de normalização que compreende a amostragem dos espectros, o ajuste de *redshift* e a suavização dos espectros pelo filtro *Moving Average*. Assim como o trabalho desenvolvido por (HARUTYUNYAN, 2008), o processamento não é totalmente automático pois alguns espectros necessitam do acompanhamento do especialista para ajustes pontuais (MÓDOLO, 2016).

A classificação é feita por redes neurais artificiais perceptron de múltiplas camadas, que utilizam como forma de aprendizado o algoritmo *backpropagation*, esta rede subdivide os espectros em dois conjuntos: treinamento (80% dos dados) e teste (20%). São treinadas 4 redes neurais para a classificação de cada tipo básico de supernova: Ia, Ib, Ic e II.

A classificação da CIntla é um marco importante pois permite a abstração do conhecimento do especialista, ou seja, do astrônomo para classificar supernovas pelo espectro, obedecendo a marcação das linhas espectrais que são usadas pelos especialistas para identificar os tipos de supernovas. Cada uma das marcações representam os elementos Si, He e H que definem cada um dos tipos básicos.

3 CONCEITOS DA TEORIA DOS CONJUNTOS NEBULOSOS

Os fundamentos matemáticos que englobam a lógica nebulosa estão relacionados a teoria dos conjuntos nebulosos, e foram abstraídos da teoria clássica dos conjuntos. A principal diferença entre a teoria clássica e a teoria dos conjuntos nebulosos reside na forma em que um elemento pertence ou não a determinado conjunto (TSOUKALAS; UHRIG, 1996).

Este capítulo apresenta a formulação matemática dos conjuntos nebulosos, características principais, estrutura e métodos de inferência.

3.1 Formulação Matemática dos Conjuntos Nebulosos

A função de inclusão na teoria clássica, é restrita em determinar se um elemento pertence ou não a determinado conjunto. Assim, a definição do pertencimento de um determinado elemento x a um conjunto particular A em um determinado universo de discurso X é dada pela função característica descrita na Equação 3.1.

$$A(x): X \rightarrow \{0,1\} \quad (3.1)$$

Ou seja, se $x \in A$ então $A(x)=1$ e se $x \notin A$ então $A(x)=0$. Diferente do que ocorre na teoria clássica dos conjuntos, em conjuntos nebulosos a definição do pertencimento de um determinado elemento x a um conjunto nebuloso B em um determinado universo de discurso X é dada pela função característica descrita na Equação 3.2.

$$B(x): X \rightarrow [0,1] \quad (3.2)$$

Ou seja, a função mapeia os valores do domínio no intervalo de $[0,1]$, indicando o grau de pertinência de um elemento. Desta forma existe a flexibilidade da função de pertencimento.

Os sistemas baseados em lógica nebulosa são implementados em diversas aplicações, tais como, o controle inteligente e a classificação de padrões (SIMOES; BOSE; SPIEGEL, 1997; NA, 1998; RODNEY; TONRY, 2009). Essas abordagens são definidas devido a característica fundamental da teoria dos conjuntos nebulosos proposta por Zadeh (1965), que consiste em aproximar um processo de decisão de maneira matemática de acordo com a percepção de um especialista humano, ou seja, um sistema computacional baseado em lógica nebulosa está apto a aproximar a decisão de um ser humano de forma automática. A característica básica deste sistema é eliminar decisões binárias, tais como, “sim” ou “não” (0 ou 1), aproximando de decisões abstratas como, “mais ou menos”, “provavelmente”, “próximo de”, “muito próximo”, “pouco provável”, etc.

3.2 Representação dos Conjuntos Nebulosos

Existem formas específicas para a representação dos conjuntos nebulosos. A primeira denota os conjuntos como uma coleção de pares ordenados. Seja um conjunto nebuloso B em um universo de discurso X e x sendo um elemento particular do universo X sua representação é expressa pela Equação 3.3.

$$B = \{(x, \mu_B(x))\}, x \in X \quad (3.3)$$

Onde cada par $(x, \mu_B(x))$ é denominado *singleton*, o elemento x é seguido pelo seu valor de pertencimento dado pela função de pertencimento $\mu_B(x)$. Seja B um conjunto nebuloso para valores de temperaturas baixas em graus °C, definidas pela função de pertencimento $\mu_B(x)$. A Equação 3.4 denota a representação do conjunto nebuloso e o valor de pertencimento de seus elementos.

$$B = \{(1, 1.0), (10, 0.7), (15, 0.4), (20, 0.2), (30, 0.1)\}, x \in X \quad (3.4)$$

Seja um conjunto nebuloso B em um determinado universo de discurso X sua forma algébrica é expressa de acordo com a Equação 3.5 e a Equação 3.6 que indicam a forma discreta e contínua respectivamente.

$$|B| = \sum_{x_i \in X} \mu_B(x_i) / x_i \quad (3.5)$$

O somatório descrito na Equação 3.5 indica a operação de união de todos os *singletons*, definidos para o universo de discurso discreto.

$$|B| = \int_X \mu_B(x) / x \quad (3.6)$$

A integral definida pela Equação 3.6, indica a operação de união de todos os *singletons*, definidos para o universo de discurso contínuo.


A função de pertencimento definida para o conjunto nebuloso B , é representada em sua forma matemática de acordo com a Equação 3.7. As funções de pertencimento são definidas com o conhecimento referente a determinada situação de representação, neste caso a função foi definida para representar baixas temperaturas em °C de acordo com o conhecimento de determinada pessoa sobre os índices de temperatura.

$$\mu_B(x) = \frac{1}{\left(1 + \left(\frac{x}{15}\right)^3\right)} \quad (3.7)$$

A Figura 3.1 indica a representação gráfica para a função de pertencimento definida na equação 3.7. De acordo com a teoria dos conjuntos nebulosos, as funções de pertencimento podem agregar além dos valores que

representam os graus de pertencimento, significados linguísticos de forma a facilitar a representação dos conjuntos (TSOUKALAS; UHRIG,1996; NEGNEVITSKY, 2005).

Figura 3.1 – Função de pertencimento para baixas temperaturas em °C



Fonte: Produção do autor.

3.3 Sistemas Nebulosos

Um sistema nebuloso (*Fuzzy System*), é um sistema baseado em um conjunto de regras do tipo *se-então* e uma base de conhecimento para inferir informações. Estes sistemas são compostos por quatro estados a que são submetidos os dados de entrada e saída:

- Normalização dos dados de entrada para a forma nebulosa de acordo com a teoria de conjuntos nebulosos, o termo correto para esta normalização é Fuzzificação.
- Construção da base de regras;
- Construção da máquina de inferência;
- Representação dos dados obtidos com os processos anteriores de forma a atribuir valores para os dados de saída do sistema, o termo correto para este processo é Defuzzificação.

Sistemas nebulosos são aproximadores formidáveis principalmente quando aplicados a problemas de controle e classificação (diagnóstico). Exemplos

destas aplicações em controle podem ser citados, tais como: Aplicações de controle nebuloso em um modelo de núcleo de reator PWR (GUIMARÃES et al., 2000); Aplicações de controladores nebulosos para componentes de reatores nucleares (GUIMARÃES; SILVA, 2002; GUIMARÃES; SILVA; BORGES, 2002); O controle adaptativo para tubos de calor (ABDALLA; FORD; GUIMARÃES, 1992); O controle de um gerador de vapor de tubo e análises de ruído caótico (SILVA, 2001), (SILVA; GUIMARÃES; OLIVEIRA JÚNIOR, 2001), (SILVA; GUIMARÃES, 2001); A automatização do controle de temperatura (LIN, 2004); O controle do nível de água para geradores de vapor nuclear (NA,1998); O controle de velocidade para sistemas de geração de energia eólica (SIMOES; BOSE; SPIEGEL, 1997). Aplicações voltadas à classificação e diagnósticos também demonstram um bom desempenho dos sistemas nebulosos, por exemplo: Sistema para estimação e identificação de parâmetros e perfis de regiões da ionosfera (PILLAT; FAGUNDES; GUIMARÃES, 2015) (PILLAT; FAGUNDES; GUIMARÃES, 2014), (PILLAT, 2012), (PILLAT et al., 2013), (PILLAT; GUIMARÃES, 2014), (PILLAT; GUIMARÃES, 2010); Sistema para análise de gás em transformadores de potência(YANG; LIAO, 1999); Diagnósticos de doenças (MOUSA; MUNIB; MOUSSA, 2005; CHEN,2013); A classificação e estimação de parâmetros de supernovas pela curva de luz (RODNEY; TONRY, 2009).

3.3.1 Variáveis Linguísticas e Normalização


A inserção de termos linguísticos é definida por um conjunto de funções de pertencimento que modelam o conhecimento de determinada pessoa sobre um problema.

Uma variável linguística é definida onde os valores possíveis são conjuntos nebulosos. Este tipo de variável pode ser definida como uma tripla $(K, U, T(K))$ em que K é uma variável, U é o universo de discurso de K e $T(K)$ é um conjunto de funções de pertencimento nebulosas em K , chamados termos linguísticos (DRUMMOND, 2004). Um termo linguístico é um conjunto

nebuloso. Os termos linguísticos especificam uma variável linguística, que são caracterizadas por funções de pertencimento (SANDRI; CORREA, 1999).

Assumindo o problema da temperatura definindo anteriormente, uma modelagem nebulosa dos termos linguísticos pode ser dada pela representação da variável temperatura. Esta variável pode ser modelada de acordo com a lógica nebulosa assumindo valores dos termos linguísticos de um conjunto de funções de pertencimento {frio, agradável, quente}. Um exemplo clássico de variáveis linguísticas é ilustrado pela Figura 3.2.

Figura 3.2 – Variáveis linguísticas para temperatura, representadas por funções de pertencimento



Fonte: Produção do autor.

O uso de variáveis linguísticas também é difundido na normalização dos dados de entrada de um sistema nebuloso, propiciando a representação da informação imprecisa.

3.3.2 Relações e Regras Nebulosas

As relações nebulosas são conjuntos nebulosos definidos em um universo de discurso. A relação nebulosa implica na ausência ou presença de associação entre elementos de diferentes conjuntos nebulosos. O valor da função de pertencimento das relações nebulosas indica o grau em que os elementos estão associados (TSOUKALAS; UHRIG, 1996).

Se o grau de associação é 0 ou 1, ou seja, de acordo com a teoria clássica dos conjuntos, a relação é caracterizada como relação *crisp* (os elementos

possuem associação ou não possuem). Quando o grau de associação está contido no intervalo entre 0 a 1, então existe uma relação nebulosa. Uma relação pode ser expressa por um conjunto de regras do tipo **se-então**.

Em sistemas nebulosos a informação sobre determinado problema é modelada por regras nebulosas, tais regras, são representações formais do problema a ser modelado e oferecem uma alternativa a representação analítica, meramente numérica, propiciando a inserção de formas linguísticas utilizadas por especialistas no cotidiano de forma a resolver problemas em determinada área. As regras são definidas como sendo do tipo:

- **SE** {condição} **ENTÃO** {consequência}.

As regras nebulosas, são utilizadas para definir matematicamente um conhecimento ou informação imprecisa e são classificadas como regras implicativas (condição e consequência) e regras conjuntivas em que estão sujeitas aos operadores lógicos (**E**, **OU**, **NÃO**) (TSOUKALAS; UHRIG, 1996; DRUMMOND, 2004; NEGNEVITSKY, 2005).

Diferente do que ocorre com a lógica clássica, onde a inferência é obtida através da manipulação dos símbolos, a lógica nebulosa possui a inferência através da manipulação numérica das funções de pertencimento.

3.3.3 Máquina de Inferência

Os mecanismos de inferência definem como as informações (dados de entrada) e as regras nebulosas devem ser combinados para gerar novas informações. A inferência em sistemas nebulosos pode ser definida em dois casos:

- Composição de regras: Dada uma entrada, um conjunto de regras é ativado e determina a saída final da máquina de inferência.
- Regra individual: Dada uma entrada, cada regra determina um conjunto nebuloso de saídas, e a saída final da máquina de inferência é dada pela combinação dos conjuntos nebulosos de saída.

Existem na literatura, diferentes mecanismos de inferência que são utilizados em aplicações distintas. Alguns modelos de inferência podem ser citados como: o Modelo de inferência de Takagi e Sugeno e o Modelo de Inferência de Mamdani (TAKAGI; SUGENO,1985; TSOUKALAS; UHRIG, 1996).

O modelo de Inferência de Takagi-Sugeno consiste em um tipo de inferência capaz de descrever funções de forma aproximada e é muito utilizado em aplicações de controle. Este modelo permite a aproximação uniforme de funções em um domínio específico. As etapas para o desenvolvimento do modelo são: a seleção de entradas; a modelagem das regras e a escolha das funções de pertencimento; a ativação das regras; e a inferência. Desta forma, este modelo permite que se tenha uma relação linear de entrada e saída (*input-output*) (TAKAGI; SUGENO,1985).

A principal diferença entre o modelo de inferência de Takagi-Sugeno e de Mamdani é que as funções de associação de saída neste modelo, são lineares ou constantes.

As regras deste modelo são descritas pela equação 3.8.

$$\text{Se } k_1 \text{ é } B_1 \text{ e } k_2 \text{ é } B_2 \dots k_n \text{ é } B_n, \text{Então } y = f_i(k_1, k_2, k_3 \dots k_n) \quad (3.8)$$

Em que B_1, \dots, B_n são os conjuntos nebulosos dos antecedentes enquanto que o conseqüente f_i é uma função das variáveis de entrada $k_1, k_2, k_3, \dots, k_n$ e n é o número de regras que são ativadas. As funções f_i representam os polinômios gerados pela inferência do modelo que é representada pela equação 3.9. A saída gerada por este sistema de inferência é polinomial (TAKAGI; SUGENO,1985).

$$y = \frac{\sum_{i=1}^n w_i f_i(k_1, k_2, k_3, \dots, k_n)}{\sum_{i=1}^n w_i} \quad (3.9)$$

A ativação das regras é dada por um operador de implicação e é definido

pela variável W_i . Este operador é análogo ao operador de implicação de Mamdani min e é definido para interpretar as informações das regras **se-então** interpretando os conectivos E, OU e CASO CONTRÁRIO. A equação 3.10 indica o operador de implicação de Mamdani Min.

$$\phi[\mu_A(x), \mu_B(y)] \equiv \mu_A(x) \wedge \mu_B(y) \quad (3.10)$$

No modelo de Takagi-Sugeno de ordem zero as regras são definidas conforme a equação 3.11.

$$\text{Se } k_1 \text{ é } B_1 \text{ e } k_2 \text{ é } B_2 \dots k_n \text{ é } B_n, \text{ Entao } y = S \quad (3.11)$$

Tem-se um modelo de Takagi-Sugeno de ordem zero se o polinômio f_i é uma constante. Neste ponto, S é definida como um conseqüente, ou seja, uma variável de saída que é dependente das variáveis de entrada k_n . Esta variável assume valores constantes e pode ser representada também por termos linguísticos e seus respectivos valores. A saída gerada é um polinômio de ordem zero.

Quando a saída é uma constante as funções de associação são definidas como *singletons*, e os métodos de implicação e agregação das regras são fixos (SUGENO, 1985; SUGENO; KANG, 1988; JUANG; LO, 2008). A equação 3.12 descreve a inferência para o modelo de Takagi-Sugeno de ordem zero.

$$y = \frac{\sum_{i=1}^n w_i S_i}{\sum_{i=1}^n w_i} \quad (3.12)$$

O método de inferência de Takagi-Sugeno de ordem zero aplicado neste trabalho foi escolhido pela forma como as saídas são geradas da avaliação

nebulosa. Este modelo permite que o custo computacional para realizar as operações nebulosas seja reduzido, pois os consequentes são polinômios de grau zero. Para este sistema automático a redução no número de operações e a redução de complexidade do algoritmo permite maior agilidade na identificação e classificação de supernova.

3.3.4 Representação das Saídas

A representação das saídas em um sistema nebuloso é dada pela decodificação das entradas que foram submetidas aos processos anteriores (normalização, conjunto de regras e máquina de inferência) gerando uma saída. Esta decodificação é denominada defuzzificação do termo em inglês *defuzzification*, existem tipos distintos de métodos para defuzzificação:

- Centro das Somas: gera a saída resultante tomando a soma da saída de cada regra nebulosa. Executa uma média simples.
- Média Máxima: determina os pontos em que o grau de pertencimento é máximo, a saída decodificada é o valor obtido a partir da média dos valores dos pontos máximos.
- Centro de Área: O valor de saída é o centro da gravidade da função de distribuição da possibilidade da ação de controle. Executa uma média ponderada.

Estes métodos permitem que se abstraia do sistema nebuloso as saídas para o controle ou a classificação das informações que foram codificadas.

É importante ressaltar que este trabalho é uma aplicação da lógica nebulosa para a classificação de supernovas, ou seja, não é referente ao desenvolvimento de novos métodos e regras nebulosas para a inferência de informações.

4 CONCEITOS SOBRE O FILTRO DE SAVITZKY-GOLAY

O uso de sistemas de filtragem trata de um dos problemas clássicos de processamento de sinais. Este problema reside na compensação da distorção e modificação de forma em sinais surgida quando um sinal é capturado e transmitido através de um sistema físico.

O objetivo do tratamento de sinais pela filtragem é a questão da transmissão e manipulação de dados sem distorção. Este tratamento propicia uma forma mais segura de avaliação de sinais para a representação dos fenômenos físicos. Os sinais tratados neste trabalho apresentam-se no domínio de tempo discreto sendo necessária a aplicação de filtros digitais.

Este capítulo apresenta os conceitos matemáticos e fundamentos sobre o filtro Savitzky-Golay aplicado para a normalização dos dados espectrais de supernovas neste trabalho. A aplicação deste filtro permitiu a construção de um sistema de filtragem dupla para otimização e garantia da qualidade dos dados de entrada submetidos ao sistema SUZAN.

4.1 Fundamentos Matemáticos do Filtro Savitzky-Golay

O filtro Savitzky-Golay, é caracterizado por ser um filtro digital FIR, onde sua resposta ao impulso unitário tem um número finito de amostras não nulas. Este filtro foi proposto em 1964, por Abraham Savitzky e Marcel J.E. Golay, para a construção de um sistema de tratamento de ruídos e análise de componentes químicos em espectros (SAVITZKY; GOLAY, 1964; LUO et al. 2005; SCHAFFER, 2011).

Este filtro é desenvolvido segundo a combinação de duas características nos filtros FIR: a equivalência entre a filtragem digital passa-baixa e a suavização de ruído por polinômios. Esta abordagem consiste da interpolação de um conjunto de dados pelo método dos mínimos quadrados.

A execução de um *fitting* polinomial por mínimos quadrados é feita pela convolução dos dados de entrada em uma janela de tamanho $2m+1$, determinando o valor suavizado do ponto central do conjunto de dados

através de uma regressão polinomial de grau k deslocando a janela ponto a ponto até que todo o conjunto de dados seja suavizado.

O processo de filtragem é constituído pelo desenvolvimento do método de média ponderada, conforme indica a equação 4.1.

$$s_i^* = \frac{\sum_{j=-m}^{j=m} c_j s_{i+j}}{N} \quad (4.1)$$

Onde s_i^* é o resultante da suavização, ou seja, é o valor suavizado; o coeficiente c_j é o coeficiente para a j -ésima suavização; s_i é o valor dos coeficientes do filtro de Savitzky-Golay; N é o tamanho da janela de pontos do filtro que é dada por $2m+1$, ou seja, um conjunto de pontos ímpar. O índice i representa os pontos dos dados originais.

A essência da filtragem é a adoção de um polinômio em uma janela de pontos para se ajustar ao sinal original, ponto a ponto. Este polinômio é gerado pela aplicação do método de mínimos quadrados dado pela equação 4.2.

$$f_k(j) = a_0 + a_1 j + a_2 j^2 + \dots + a_k j^k = \sum_{n=0}^k a_n j^n, j \leq 2m \quad (4.2)$$

Onde j assume os valores de $j = -m, -m+1, \dots, m-1, m$. Os valores de a_n são referentes aos coeficientes deste polinômio e k é referente ao grau do polinômio. Os valores são encontrados pela formação de um sistema de equações lineares, resolvido na forma matricial pelo método de mínimos quadrados descritos pelas equações 4.3, 4.4 e 4.5.

$$\left\{ \begin{array}{l} s_{-m}^{i-m} = a_0 + a_1(-m) + a_2(-m)^2 + \dots + a_k(-m)^k \\ s_{-m+1}^{i+(-m+1)} = a_0 + a_1(-m+1) + a_2(-m+1)^2 + \dots + a_k(-m+1)^k \\ \vdots \\ s_0^{i+(0)} = a_0 \\ \vdots \\ s_{m+1}^{i+(m-1)} = a_0 + a_1(m-1) + a_2(m-1)^2 + \dots + a_k(m-1)^k \\ s_{-m}^{i+(m)} = a_0 + a_1(m) + a_2(m)^2 + \dots + a_k(m)^k \end{array} \right. \quad (4.3)$$

$$s = M \cdot a \quad (4.4)$$

$$a = (M^T M)^{-1} M^T s \quad (4.5)$$

A efetiva suavização é construída extraíndo o sinal original do ambiente de ruído enquanto mantém a forma do sinal o mais próximo possível do original.

O processo de filtragem obtido pela adoção dos parâmetros de tamanho de janela e de grau de polinômio obedece a seguinte relação:

1. quanto maior o parâmetro da janela e menor o grau de polinômio o sinal de saída resultante é apresentada como uma suavização rígida, ou seja, o sinal de saída apresenta distorção;
2. quanto menor o tamanho da janela de pontos e maior o grau do polinômio o sinal resultante de saída é apresentado como um sinal ruidoso.

A escolha dos parâmetros de janela e de grau de polinômio, influenciam no desempenho do filtro, a escolha destes parâmetros para o projetista do filtro deve ser baseada pela resposta em frequência previamente determinada. Em relação ao parâmetro de grau de polinômio, esta escolha deve ser baseada na banda de passagem do filtro, isto é, quanto maior o grau do polinômio maior a largura da banda passante. Desta forma, o aumento da banda passante gera a ineficiência do filtro para o tratamento de sinais de distribuição gaussiana.

É necessário para o tratamento de diversos sinais a adoção de um equilíbrio que permita uma suavização coerente garantindo a permanência de informações importantes no sinal. Esta escolha pode ser relacionada ao tipo de sinal tratado, a resposta do filtro a uma dada frequência preestabelecida, ao tamanho da banda passante, e ao custo computacional (FERNANDES,2017).

O sistema de filtragem proposto neste trabalho visa a aplicabilidade do filtro

Savitzky-Golay para filtragem de dados espectrais, de forma a garantir a manutenção das características de forma do sinal eliminando o ruído para a localização das linhas de emissão e absorção, gerando um sistema de processamento prévio com baixo custo computacional, homogêneo e uniforme para uma grande quantidade de espectros de supernovas.

O uso de um sistema de filtragem nem sempre garante a qualidade do sinal para análise, pois ainda os ruídos podem aparecer nas amostras de dados. Desta forma, o processo de filtragem dupla desenvolvido neste trabalho caracteriza um sistema em que o sinal ruidoso é removido, o deslocamento dos comprimentos de onda são mínimos, as características de forma do sinal original são mantidas, as amostras de atraso no sinal filtrado em relação ao sinal original são reduzidas e a busca gradiente evidencia apenas os mínimos e máximos locais utilizados na análise de composição de elementos em espectros. Neste sentido a dupla filtragem promove a otimização sobre o dado de uma filtragem simples.

A construção desta etapa, bem como da análise do sistema de filtragem dupla e de seus resultados é descrita no capítulo 5, referente a Engenharia do Conhecimento para interpretação de dados de espectros de supernovas.

5 ENGENHARIA DO CONHECIMENTO

O modelo de classificação espectral de supernovas foi denominado Sistema fUZzy Avaliador de superNovas (SUZAN). O classificador SUZAN é relacionado ao sistema Classificador Inteligente de supernovas do tipo Ia CIntla desenvolvido por Módolo (2016) sendo uma continuação deste trabalho, mas explorando o paradigma de lógica nebulosa.

A importante relação entre a SUZAN e o trabalho realizado por Módolo (2016), está na concepção de um sistema que não esteja estritamente relacionado ao pertencimento de elementos a uma determinada linha espectral, ou seja, neste ponto evita-se a análise puramente algorítmica e se permite o trabalho com a incerteza. A construção da CIntla permitiu que fossem abstraídas regras para a classificação espectral de supernovas. Com estas regras de classificação foi possível definir em certo grau quanto uma linha espectral pode representar ou não determinados elementos em regiões específicas do espectro. Assim, o conceito de lógica nebulosa é aplicável pois permite que esta incerteza seja modelada e que se construam mecanismos capazes de simular o astrônomo no momento da análise espectral.

Este capítulo é destinado a mostrar os passos executados na escolha e no processamento dos dados espectrais de supernovas, indicando as técnicas usadas no processamento dos sinais para a normalização das amostras de entradas no sistema SUZAN.

5.1 Dados dos Espectros de Supernovas

Os dados de espectros de supernovas utilizados neste trabalho são públicos disponibilizados gratuitamente pelo acervo do *Harvard-Smithsonian Center for Astrophysics* (Cfa) (HARVARD-SMITHSONIAN CENTER FOR ASTROPHYSICS, 2016).

Este acervo contém espectros de supernovas dos tipos Ia, Ib, Ic e II. Os espectros contidos nas bases de dados possuem diversidade em relação a:

- quantidades de instrumentos de coleta de dados;
- variação nos comprimentos de onda dos espectros;
- variação das intensidades;
- variação em relação as fases das supernovas, compreendendo longos períodos de observação.

As relações sobre as fases espectrais e de dias de observação são explicadas no capítulo 2, na subseção destinada às características espectrais de supernovas. A Tabela 5.1 indica os períodos relacionados às fases espectrais de supernovas utilizadas neste trabalho, indicando um período de brilho máximo de -2.5 dias a +2.5 dias em relação ao pico de luminosidade máxima da curva de luz de supernova. Este período foi selecionado por Blondin et. al (2011), como sendo o período próximo ao brilho máximo em que se identificam melhor as características das supernovas Ia.

Tabela 5.1 – Fases de observação utilizadas

Fase Espectral Mínima (dias)	Fase Espectral Máxima (dias)	Período
-10	-2.5	Antes do Máximo
-2.5	+2.5	Brilho Máximo
+2.5	+7	Depois do Máximo
+7	+10	Fase Intermediária
+10	+45	Pré-Nebular
+45	+60	Nebular

Fonte: Produção do autor.

A Tabela 5.2 indica a organização dos dados, contendo a referência de cada acervo, bem como o tipo de supernova, a quantidade de supernovas de cada tipo e a quantidade de espectros.

Tabela 5.2 – Organização dos dados espectrais de supernovas

Id.	Referências dos Dados	Tipo SN	Qtde. SN	Qtde. Espectros
1	BLONDIN, S.; MANDEL, K. S.; KIRSHNER, R. P., 2011.	Ia	26	47
2	BLONDIN, S. et al. 2012.	Ia	462	2603
3	MATHESON, T. et al, 2008.	Ia	32	432
4	MODJAZ, M. et al, 2014.	Ib	24	217
5	MODJAZ, M. et al, 2014.	Ic	31	282
6	MODJAZ, M. et al, 2014.	II	13	116
Total			588	3697

Fonte: Produção do autor.

As próximas subseções descrevem as características dos bancos de dados, indicando os instrumentos de coleta, as características dos espectros coletados e dos períodos de observação destes espectros. Cada banco é identificado conforme o Índice (Id) como uma simplificação para organização nas próximas seções.

5.1.1 Considerações sobre o Banco 1 de Supernovas de Tipo Ia

Os espectros do Banco 1 (Tabela 5.2) são dispostos em arquivos no formato `ascii` com as colunas para o comprimento de onda em [Å] e o fluxo de radiação em [1e-15 erg/s/cm²/Å], contendo espectros de supernovas do tipo Ia.

A maioria dos espectros deste banco foram obtidos pelo telescópio **FLWO 1.5m+FAST**, com exceção da supernova SN 2003ch, a qual foi obtida pelos telescópios **MMT 6.5m+Bluechannel** e **FLWO1.5m+FAST**.

A observação das supernovas neste banco são relacionadas apenas ao período de brilho máximo. Ou seja, em um período de dias bem próximo ao pico de luminosidade máximo da curva de luz. As características deste banco são descritas da seguinte forma:

- fase espectral de -2.5 a +2.5 dias em relação ao brilho máximo;
- comprimento de onda variando de 3800 a 7200 angstroms;
- escala dos espectros por um fator de 1e-15 erg/s/cm²/Å;

É importante dizer que esta amostra de dados foi separada especificamente por astrônomos especialistas que manualmente identificaram, de acordo com seus conhecimentos, os tipos de supernovas representadas nestes espectros.

Estes espectros foram selecionados por Blondin et. al (2011), para medição de distâncias astronômicas, verificando em supernovas de tipo Ia a baixos *redshifts*, métricas de modo a contribuir para as pesquisas que tratam da expansão cósmica. Neste sentido esta separação manual por especialistas apenas conseguiu abstrair 47 espectros de 26 supernovas diferentes.

A separação das supernovas do banco 1, foi feita para espectros apenas em um período próximo ao brilho máximo, indicando que os especialistas conseguem classificar este tipo de supernova e identificar os perfis de supernova Ia com maior facilidade neste período.

5.1.2 Considerações sobre o Banco 2 de Supernovas de Tipo Ia

Os espectros do Banco 2 (Tabela 5.2) são dispostos em arquivos no formato ascii com as colunas para o comprimento de onda em [Å] e o fluxo de radiação em [erg/s/cm²/Å], contendo espectros de supernovas de tipo Ia.

Estes espectros foram obtidos por uma grande variedade de instrumentos de coleta e são dispostos na Tabela 5.3 abaixo.

Tabela 5.3 – Instrumentos de coleta de dados para o Banco 2

Espectrógrafo	Telescópio
fast	FLWO
mmt	MMT
ldss2	Magellan Clay
ldss3	Magellan Clay
imacs	Magellan Baade

Fonte: Produção do autor.

As variações nas intensidades do fluxo dos espectros foram baseadas na extração do algoritmo de Horne (1986). Entretanto, muitos dos espectros da base não possuem informações para correção do erro e variações de escalas e intensidades.

Os espectros contidos no banco 2 possuem observações de supernovas da captura inicial do espectro até muitos dias após a explosão da estrela. Obtendo espectros de supernovas das fases iniciais da explosão até aproximadamente +2 anos de observação, compreendendo as fases iniciais, as fases próximas ao brilho máximo e as fases nebulares. As características destes espectros são descritas a seguir:

- fases espectrais de -15 a +611 dias em relação ao brilho máximo;
- comprimento de onda variando de 3000 a 10800 angstroms;

A não padronização destes dados, tanto pelas diferentes calibrações dos instrumentos de coleta, como por ruídos naturais torna o conjunto repleto de variações, tais como:

- escalas;
- comprimento de onda;
- variações nos fluxos de radiação de cada espectro;
- variações nos períodos de observação de supernovas;

O banco 2 é considerado o banco mais heterogêneo coletado, tanto pela quantidade de fases como pela quantidade de instrumentos utilizados para captura dos espectros, contabilizando um total de 5 instrumentos diferentes. Este banco foi separado desta maneira para observação da variedade e diversidade do tipo Ia, compreendendo todas as suas fases. O artigo em que estes espectros são introduzidos foi denominado: “*The Spectroscopic Diversity of Type Ia Supernovae*” (BLONDIN et al, 2012).

5.1.3 Considerações sobre o Banco 3 de Supernovas de Tipo Ia

Os espectros do Banco 3 (Tabela 5.2) são dispostos em arquivos no formato ascii com as colunas para o comprimento de onda em [Å] e o fluxo de radiação em [erg/s/cm²/Å] em escala dada por um fator de 10¹⁵, contendo espectros de supernovas do tipo Ia.

Todos os espectros deste banco foram obtidos pelos espectrógrafos **FAST e MMT**. Os espectros deste banco foram ajustados para combinar com a Banda fotométrica V (JHA et al., 2006). Alguns espectros também encontram-se fora deste ajuste, de modo que o fluxo de radiação contido nos espectros torna-se impreciso e com erros de interpolação ou extrapolação.

Existe neste banco, um extenso conjunto de espectros obtidos várias semanas após o brilho máximo, estando na fase nebular. Os espectros observados em fases maiores de +10 dias em relação ao brilho máximo, possuem uma dispersão relativamente alta da ordem de $\sigma = 0,15$. As características destes espectros são descritas a seguir:

- fases espectrais de -13 a +243 dias em relação ao brilho máximo;
- comprimento de onda variando de 3000 a 7500 angstroms;

Existe uma série de fatores que explicam estas variações e uma delas é que a medida em que o espectro “envelhece”, torna-se cada vez mais dominado pelas linhas de emissão, de modo que a convolução com um filtro que não é compatível com a fotometria pode apresentar um erro sistemático.

Outro ponto a ressaltar é que alguns espectros contidos na base se apresentam com intensidades pequenas, de modo que existe a contaminação do espectro da supernova com os elementos presentes na galáxia hospedeira.

Em síntese, é válido ressaltar que os espectros contidos nesta base de dados apresentam muitas inconsistências e variações, além de compreender fases de supernovas Ia para além do brilho máximo, considerando a observação do fenômeno em muitos dias.

5.1.4 Considerações sobre os bancos 4,5 e 6 de Supernovas de Colapso de Núcleo

Os espectros dos Bancos 4,5 e 6 (Tabela 5.2) de tipos de supernova de colapso de núcleo (Ib,Ic e II) são dispostos em arquivos no formato ascii com as colunas para o comprimento de onda em [Å] e o fluxo de radiação em [erg/s/cm²/Å], entretanto sem informações sobre ajustes de escalas contidos no banco.

Assim como os espectros contidos no Banco 2 (Tabela 5.2), os espectros contidos nos Bancos 4, 5 e 6 também foram coletados com uma grande variedade de instrumentos. A tabela 5.4 indica estes instrumentos de coleta.

Tabela 5.4 – Instrumentos de coleta de dados para os Bancos 4,5 e 6

Espectrógrafo	Telescópio
fast	FLWO
IMACS	Magellan
Idss2	Magellan Clay
Idss3	Magellan Clay
MMTblue	MMT
MMTred	MMT

Fonte: Produção do autor.

Em relação a diversidade de observações, ou seja, aos períodos de observação, os espectros contidos nestes bancos possuem observações que compreendem as fases iniciais, a fase de brilho máximo e as fases nebulares. Os espectros destas supernovas possuem observações para +2 anos em relação ao pico de luminosidade máximo das supernovas.

É importante ressaltar que para cada tipo de supernova as curvas de luz evoluem de maneira diferente. Ou seja, seu pico de luminosidade máxima ocorre de maneira diferente para cada supernova em tempos diferentes.

Neste banco além da observação em períodos de +2 anos existem espectros

observados em longos períodos, como é o caso da supernova SN 1993J, que possui espectros de -6 dias a +2959 dias em relação ao brilho máximo.

Desta maneira, esta grande variação nos períodos de observação torna identificável os tipos apenas para supernovas capturadas próximas ao brilho máximo, pois para grandes períodos de observação, os espectros não se enquadram mais nas regras de classificação. Desta forma, existe a necessidade da construção de novos esquemas de classificação, esta premissa é fortemente relacionada a compreensão das fases nebulares.

5.1.5 Considerações Sobre os Bancos de Espectros Utilizados no Desenvolvimento da CIntla

Os Bancos usados no desenvolvimento da CIntla são relacionados como uma seleção de espectros dos bancos: Banco 2, Banco 4, Banco 5 e Banco 6 descritos na Tabela 5.2.

Esta seleção tratava de disponibilizar um conjunto de dados de maneira homogênea, retirando as inconsistências de escala, períodos de observação e dispersão espectral. A tabela 5.5 indica os espectros selecionados na versão final do sistema CIntla, por questões de organização estes dados são rotulados na sequência dos bancos originais (Tabela 5.2) que foram explicados anteriormente seguindo a identificação de Banco 7, Banco 8, Banco 9 e Banco 10.

Tabela 5.5 – Organização dos dados espectrais de supernovas no Sistema CIntla

Id.	Referências dos Dados	Tipo SN	Qtde. SN	Qtde. Espectros
7	BLONDIN, S. et al. 2012.	Ia	192	559
8	MODJAZ, M. et al, 2014.	Ib	12	33
9	MODJAZ, M. et al, 2014.	Ic	12	44
10	MODJAZ, M. et al, 2014.	II	5	13
Total			221	649

Fonte: Produção do autor.

Módolo (2016) desenvolveu uma seleção dos espectros para utilização no sistema CIntla com o objetivo de considerar um intervalo menor de dias de observação, para selecionar os espectros mais próximos do período de brilho máximo. Os critérios de seleção utilizados por Módolo (2016) são descritos a seguir:

- comprimento de onda: de 3800 a 7400 angstroms;
- período de observação da fase da supernova de -3 a +7 dias em relação ao brilho máximo;
- dispersão espectral: menor ou igual a 1,5 angstroms por pixel;

Estes bancos utilizados pela CIntla além da separação das inconsistências foi dividido em 80% para o treinamento da rede neural e 20% para testes e validações na classificação (MÓDOLO, 2016).

As tabelas 5.6 e 5.7 indicam esta separação dos espectros utilizados para treino e teste da rede neural, respectivamente.

Tabela 5.6 – Organização dos dados espectrais de supernovas no sistema CIntla para treinamento da rede neural

Id.	Referências dos Dados	Tipo SN	Qtde. SN	Qtde. Espectros
7	BLONDIN, S. et al. 2012.	Ia	154	453
8	MODJAZ, M. et al, 2014.	Ib	10	28
9	MODJAZ, M. et al, 2014.	Ic	10	38
10	MODJAZ, M. et al, 2014.	II	4	12
Total			178	531

Fonte: Adaptado de Módolo (2016).

Tabela 5.7 – Organização dos dados espectrais de supernovas no sistema CIntla para teste da rede neural

Id.	Referências dos Dados	Tipo SN	Qtde. SN	Qtde. Espectros
7	BLONDIN, S. et al. 2012.	Ia	38	106
8	MODJAZ, M. et al, 2014.	Ib	2	5
9	MODJAZ, M. et al, 2014.	Ic	2	6
10	MODJAZ, M. et al, 2014.	II	1	1
Total			43	118

Fonte: Adaptado de Módolo (2016).

Como uma forma de comparação em relação à quantidade de espectros avaliados pelo classificador SUZAN, o classificador CIntla, avalia cerca de 221 supernovas dos tipos clássicos (Ia, Ib, Ic e II) com 649 espectros diferentes (MÓDOLO, 2016). SUZAN tem a capacidade de avaliar e analisar cerca de 3697 espectros de 588 supernovas diferentes além dos espectros selecionados pelo CIntla, contabilizando uma análise feita para uma grande amostra de dados, que em certos momentos não se apresentam como dados homogêneos e ajustados, de forma que além do ruído que deve ser tratado para avaliação dos espectros, conforme é mostrado na próxima seção, existem erros de escalas e erros causados pela diversidade de instrumentos de coleta.

Estes dados foram selecionados para gerar um sistema de análise e classificação de supernovas aplicável a um grande número de amostras para gerar a simulação de uma análise real, ou seja, uma análise feita por um telescópio que captura espectros de supernovas em diversos períodos. Ainda assim, em sistemas reais existe o ajuste e a redução de incertezas principalmente quando são tratadas das intensidades e escalas dos espectros voltadas para um instrumento de coleta específico. Desta forma, os dados gerados por este instrumento estariam com um ajuste específico.

5.2 Tratamento de dados Espectrais

Para a construção do modelo de análise espectral foram pesquisadas algumas técnicas que permitiram retirar informações do espectro relacionadas às linhas de emissão e de absorção.

Para a aplicação dos dados de espectros de supernovas no sistema SUZAN é necessário um processamento prévio de dados, ou seja, todos os espectros necessitam passar por uma etapa de tratamento e normalização.

Este processamento deve existir quando os dados estão sujeitos a interferências e ruídos. Este tipo de característica existe em dados de diversos tipos de fenômenos tais como: dados de radar, dados espectrais, imagens, séries temporais, dados relacionados a trajetos de aeronaves, etc.

Estes dados podem sofrer com inconsistências geradas por: questões atmosféricas, calibragem, refração e reflexão, ruídos nos sinais, etc. Quando este tipo problema está presente nos dados a precisão e acurácia da análise é comprometida.

Este processo é dividido em cinco etapas que são explicadas nas próximas seções:

- a construção de um sistema de dupla filtragem de dados utilizando o filtro de Savitzky-Golay;
- o cálculo e ajuste de *Redshift* nos espectros de supernova;
- a construção de um sistema de busca das linhas de emissão e absorção no espectro;
- o cálculo da distância relativa entre as linhas encontradas nos espectros e as linhas espectrais obtidas no laboratório;
- a abstração dos parâmetros de qualidade das linhas espectrais;

5.2.1 Sistema de Filtragem Dupla pelo Filtro de Savitzky-Golay

Esta seção aborda a construção do sistema de dupla filtragem utilizando o filtro de Savitzky-Golay, indicando os principais mecanismos e as repostas deste sistema em comparação a outros filtros pesquisados.

Os esquemas de filtragem utilizados neste trabalho são divididos em dois grupos: Sistemas de Filtragem Simples e Sistemas de Filtragem Dupla.

Nestes dois grupos são aplicados os filtros de Savitzky-Golay, Média Móvel (*Moving Average*) e o filtro de Wiener.

São avaliados os desempenhos dos sistemas para os sinais de espectros de supernovas, avaliando os parâmetros de qualidade definidos anteriormente:

- o deslocamento mínimo dos comprimentos de onda do sinal original;
- a manutenção da forma original do sinal;
- a atenuação do ruído no sinal;
- e a qualidade da busca de gradientes relacionada aos mínimos e máximos locais, ou seja, para a análise correta de cada pico e vale do sinal.

As próximas subseções descrevem a construção deste sistema de tratamento de dados, bem como a contextualização do filtro de Savitzky Golay e a comparação com outros filtros utilizados.

5.2.1.1 Metodologia Utilizada na Construção do Sistema de Filtragem Dupla

O sistema de dupla filtragem foi desenvolvido em linguagem de programação Python, e engloba a construção de um sistema de ajuste de dados para diversos tipos de sinais.

Os sinais de entrada inicialmente são amostrados em 1000 pontos e submetidos a uma interpolação linear simples, ponto a ponto, em que os

pontos iniciais e finais são referentes aos comprimentos de onda iniciais e finais do espectro original.

O sinal modificado é normalizado em relação aos fluxos para o vetor de magnitude 1, em que são encontrados o ponto máximo (max) e mínimo (min) do vetor de fluxo de radiação. A Equação 5.1 indica esta normalização.

A normalização feita para os fluxos não altera as escalas de cada espectro, que são dadas por um fator específico relacionado a cada instrumento de coleta de dados, apenas normaliza os valores em uma faixa de 0 a 1.

$$FN = \frac{(\text{fluxo} - \min(\text{fluxo}))}{(\max(\text{fluxo}) - \min(\text{fluxo}))} \quad (5.1)$$

Onde:

- FN: é o vetor de fluxo normalizado em magnitude 1.
- fluxo: são os valores de fluxo para cada comprimento de onda.
- max() e min() são funções para encontrar o valor máximo e mínimo do vetor de fluxo.

Os filtros utilizados neste trabalho foram:

- Savitzky-Golay;
- Média Móvel (*Moving Average*);
- Filtro de Wiener;

Os filtros *Moving Average* e o filtro de Wiener foram utilizados para fins de comparação com desempenho do filtro de Savitzky-Golay. Esta comparação é feita na filtragem simples e na filtragem dupla.

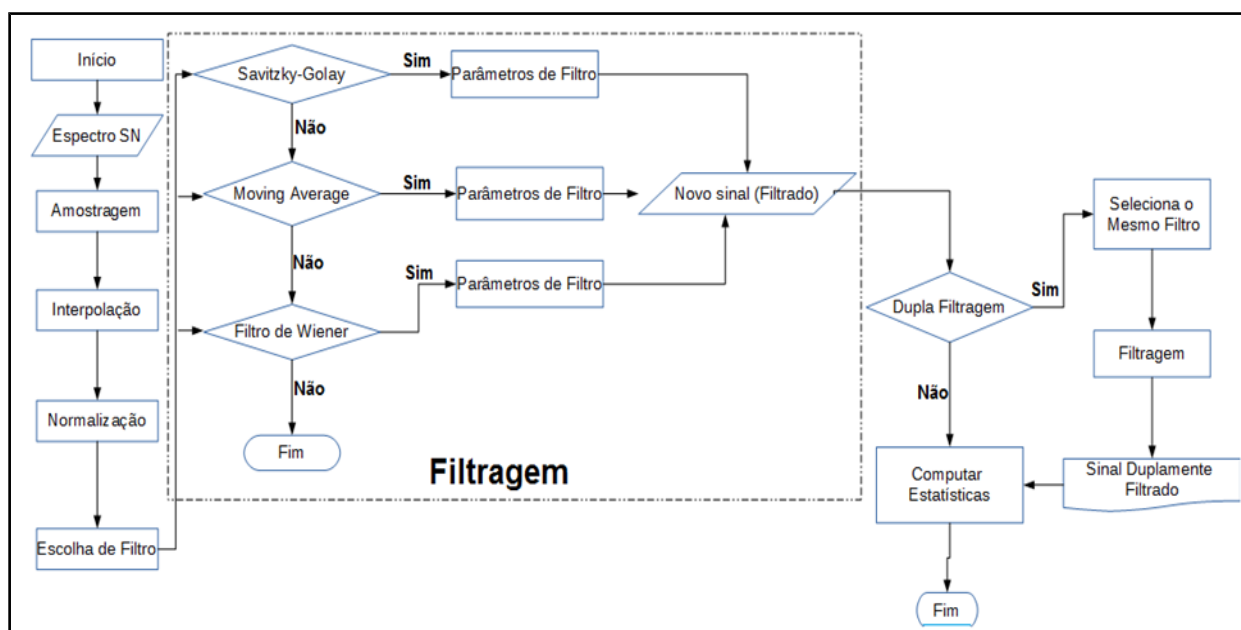
A filtragem dupla desenvolvida neste trabalho, consiste em trabalhar com os dados já filtrados de maneira a otimizar o processo de redução de ruídos e remoção de inconsistências.

O fluxo deste sistema ocorre da seguinte maneira: o sistema recebe como entrada o espectro de supernova. Em seguida, é feita a amostragem, a interpolação do sinal, ponto a ponto, e a normalização em valores de 0 a 1, dos fluxos do sinal.

Após a normalização inicial, é possível escolher entre os três filtros descritos: Savitzky-Golay, *Moving Average* ou Filtro de Wiener. Esta funcionalidade foi criada para gerar uma comparação do desempenho da filtragem feita para o filtro de Savitzky-Golay com os outros filtros. Selecionando o filtro, é feita a escolha dos parâmetros do filtro e é executada a primeira filtragem, ou seja, filtragem simples. Esta filtragem gera como saída um espectro filtrado, ou seja, um novo sinal.

O sistema permite escolher realizar uma nova filtragem ou finalizar a aplicação computando as estatísticas referentes aos parâmetros de desempenho citados anteriormente. A filtragem Dupla consiste em utilizar a saída gerada da filtragem simples como uma nova entrada e gerar uma nova filtragem, que é feita pelo mesmo filtro escolhido inicialmente. Neste ponto, a saída final é o espectro de supernova duplamente filtrado. A Figura 5.1 descreve o fluxo de dados para o sistema de filtragem.

Figura 5.1 – Fluxo de Dados do Sistema de Dupla Filtragem



Fonte: Produção do Autor.

Os parâmetros escolhidos para cada filtragem diferem em relação ao tipo de filtro utilizado, mas são equivalentes no que diz respeito ao tamanho da janela de pontos.

O filtro *Moving Average* e o Filtro de Wiener preservam esta característica para gerar um tratamento de sinais semelhante ao filtro de Savitzky-Golay. Ao contrário do filtro de Savitzky-Golay que utiliza uma janela ímpar e um polinômio para o ajuste da amostra, o filtro *Moving Average* não possui estas características, sendo mais simples de implementar.

O filtro de Wiener, por sua vez, visa estimar um sinal aleatório desconhecido, filtrando uma observação ruidosa do sinal (CHEN et al., 2006). A redução do ruído é feita mediante a combinação do tamanho da janela com a potência do ruído no sinal, que quando nula estima o ruído como sendo a média da variância local do sinal de entrada. Desta maneira, foi selecionado o nível mínimo de ruído para que o sistema obtivesse um bom desempenho em relação a suavização do sinal e na atenuação do ruído.

Estes parâmetros são definidos abaixo:

- a) parâmetros para o filtro de Savitzky-Golay: Tamanho da janela de pontos = 71; grau de polinômio = 9;
- b) parâmetros para o filtro de Média Móvel (*Moving Average*): Tamanho da janela de pontos = 70;
- c) parâmetros para o filtro de Wiener: Tamanho da janela de pontos = 70; Nível de Ruído = 1.0;

Estes parâmetros foram escolhidos para a filtragem de sinais de supernovas de acordo com o que foi utilizado nos trabalhos de Harutyunyan (2008) e Módolo et al. (2015), a fim de solucionar o problema referente a falta de uniformidade na filtragem de dados e remoção do ruído nos espectros de supernovas encontrados nestes trabalhos. Nesses trabalhos além do processamento de dados indesejáveis (ruído e mudanças morfológicas no sinal), a suavização foi feita de forma diferente para regiões específicas e alguns espectros precisaram de mais filtragem do que outros, isto é, esse processamento não foi uniforme.

Para o desenvolvimento de um sistema automático, seja ele baseado tanto em técnicas de *machine learning*, como em técnicas estatísticas um processamento homogêneo de dados é necessário, principalmente quando o especialista não está disponível para análises e ajustes “manuais”.

5.2.1.2 Medidas de Desempenho do Sistema de Filtragem Dupla

Para a análise do desempenho do sistema algumas medidas foram utilizadas, elas são descritas a seguir:

- a) o cálculo do índice de *Signal to Noise Ratio* (SNR) do sinal original e dos sinais após a filtragem simples e a filtragem dupla para a avaliação do nível de atenuação do ruído presente nos sinais.
- b) os índices de *Mean Squared error* (MSE) e de *Root Mean Square Error* (RMSE), foram utilizados para comparação entre os sinais filtrados (simples e duplamente filtrados) e o sinal original. Estas medidas são utilizadas para verificar as diferenças entre os valores preditos por um modelo (sinal filtrado) e os valores realmente observados do ambiente que está sendo modelado. As equações 5.2 e 5.3 indicam o cálculo destes índices (WILLMOT, 1982).

$$MSE = \frac{1}{N} \left(\sum_{k=1}^N (y(k) - y'(k))^2 \right) \quad (5.2)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{k=1}^N (y(k) - y'(k))^2} \quad (5.3)$$

Onde $y'(k)$ é o sinal de saída estimado, $y(k)$ é o sinal de saída obtido na filtragem.

c) os índices de correlação como o índice de *Spearman* e o índice de *Pearson* foram aplicados para identificar a manutenção das características originais do sinal, avaliando se no decorrer das filtragens houve a deformação do sinal original. Estes índices estatísticos são formalizados pelas equações 5.4 e 5.5. Os coeficientes de correlação de *Pearson* medem apenas relações lineares. Os coeficientes de correlação de *Spearman* medem apenas relações monotônicas, este índice avalia o quão bem uma função monotônica arbitrária pode descrever uma relação entre duas variáveis, sem fazer nenhuma suposição sobre a distribuição de frequência das variáveis. Desta maneira, é uma medida da força de uma associação entre duas variáveis (HAUKE; KOSSOWSKI, 2011; WEAVER et al. 2017).

$$\rho_{rank_X, rank_Y} = \frac{cov(rank_X, rank_Y)}{\sigma_{rank_X} \sigma_{rank_Y}} \quad (5.4)$$

$$\rho_{X, Y} = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}} \quad (5.5)$$

d) o índice correlação cruzada entre os sinais filtrados e o sinal original mede a similaridade dos sinais como uma função do deslocamento de um em relação a outro. A correlação cruzada entre os sinais é dada pela convolução de duas funções (sinais), a equação 5.6 descreve esta função e a 5.7 indica os índices normalizados de 1 a 0.

$$(f \star g)[n] \stackrel{\text{def}}{=} \sum_{m=-\infty}^{\infty} f^*[m] g[n + m]. \quad (5.6)$$

$$\rho_{xy} = \frac{(f*g)[n]}{\sqrt{(f*f)[0] \cdot (g*g)[0]}} \quad (5.7)$$

Onde $(f*f)[0]$ é o primeiro valor da autocorrelação cruzada do sinal original, e $(g*g)[0]$ é o primeiro valor da autocorrelação cruzada do sinal modificado (filtrado).

- e) o cálculo da distância entre os sinais filtrados e o sinal original e o cálculo dos deslocamentos nos comprimentos de onda do sinal filtrado, são medidos em relação a correlação cruzada dos sinais.
- f) a capacidade de redução na busca por picos e vales no sinal, de forma a evitar a coleta de dados ruidosos aproveitando apenas os picos e vales importantes na análise espectral.

5.2.1.3 Desempenho do Sistema de Dupla Filtragem na Aplicação de Espectros de Supernovas

O desempenho do sistema de filtragem para os sinais de supernova são medidos de duas maneiras:

- A primeira compreende a análise do sinal após a realização de uma filtragem simples. Neste ponto é comparado o desempenho de uma filtragem simples pelo Filtro de Savitzky-Golay em relação aos filtros *Moving Average* e o filtro de Wiener.
- A segunda compreende a análise do sinal filtrado que passou por uma segunda filtragem, ou seja, o sinal duplamente filtrado. Na filtragem Dupla o filtro é o mesmo, com os mesmos parâmetros da filtragem simples. Neste ponto, é comparado o desempenho da filtragem dupla pelo Filtro de Savitzky-Golay em relação aos filtros *Moving Average* e o filtro de Wiener.

O experimento foi realizado para todos os espectros de supernovas utilizados neste trabalho. Para demonstrar a aplicabilidade do sistema de dupla filtragem pelo Filtro de Savitzky-Golay, foi escolhido o espectro da supernova SN 1998aq na sua fase de brilho máximo. A tabela 5.8 indica os parâmetros e características do sinal original sem passar por nenhum processo de filtragem, indicando o índice SNR original e a quantidade de picos e vales encontrados.


Tabela 5.8– Características do Sinal Original.

Características	Sinal Original
SNR [dB]	1.306
Quantidade de Picos	190
Quantidade de Vales	191

Fonte: Produção do autor.

A Figura 5.2 ilustra o sinal original, com a localização de todos os picos e vales do sinal.

Figura 5.2 – Espectro (Sinal) original de supernova com os picos e vales encontrados



Fonte: Produção do Autor.

A tabela 5.9 indica o experimento realizado para o espectro da supernova SN 1998aq na sua fase de brilho máximo com um índice de SNR original de 1.306[dB]. A tabela demonstra o desempenho dos filtros aplicados a este sinal no sistema de filtragem simples.

Tabela 5.9 – Desempenho dos filtros no sistema de filtragem simples para o sinal de Supernova SN 1998aq, com o ruído inerente ao fenômeno.

Parâmetros de Eficiência	Filtro de Savitzky-Golay	Filtro <i>Moving Average</i>	Filtro de Wiener
SNR [dB]	1.306	1.326	1.354
MSE	4.851e-05	4.924e-4	2.959e-3
RMSE	6.965e-3	2.219e-2	5.440e-2
Correlação de <i>Spearman</i>	0.999544	0.996851	0.978450
Correlação de <i>Pearson</i>	0.999606	0.996103	0.976199
Correlação Cruzada	0.999854	0.998545	0.991252
Distancia Entre os Sinais	3.932e-4	3.896e-3	2.380e-2
Deslocamento [angstroms]	0.0	0.0	1.0
Quantidade de Picos	20	11	6
Quantidade de Vales	21	11	5


Fonte: Produção do autor.

Os dados da tabela 5.9, indicam que a filtragem simples para o filtro de Savitzky-Golay possui desempenho superior em relação aos filtros *Moving Average* e Filtro de Wiener, em manter o sinal filtrado o mais próximo do original, reduzindo significativamente os picos e vales do sinal. Isto se deve a uma boa redução do ruído presente no sinal.

A manutenção das características do sinal original no sinal filtrado pelo Filtro de Savitzky-Golay é evidente nos índices de correlação, que fazem a comparação entre o sinal original e o sinal filtrado. Todos os índices

correlacionaram o sinal em 99%. A distância entre o sinal filtrado e o sinal original e os deslocamentos também são ínfimos. A Figura 5.3 ilustra o sinal com a filtragem simples para o filtro de Savitzky-Golay. Para os índices MSE e RMSE esta filtragem também se sobressai sobre os filtros *Moving Average* e filtro de Wiener, pois sinal filtrado obtém o menor erro em relação ao sinal original.


Figura 5.3 – Filtragem simples do espectro de supernova pelo Filtro de Savitzky-Golay



Fonte: Produção do Autor.

O filtro *Moving Average*, modifica as características do sinal original. As correlações indicam que o sinal filtrado manteve razoavelmente as características do sinal original, entretanto existe uma atenuação nos picos e vales que transforma as características do sinal original, removendo os pontos que são marcantes da supernova. O índice SNR é aumentado, mas esta característica de ruído contribui para a perda de informações importantes do sinal original, isso é observado na quantidade de picos e vales encontrados após esta filtragem. A Figura 5.4 ilustra o sinal filtrado pelo filtro *Moving Average*.


Figura 5.4 – Filtragem simples do espectro de supernova pelo Filtro *Moving Average*



Fonte: Produção do Autor.

O filtro de Wiener apresenta um deslocamento, e reduz a similaridade com o sinal original. Em contrapartida, o índice SNR é aumentado, desta maneira o sinal é observado como possuindo mais ruído do que o sinal original. O sinal filtrado pelo filtro de Wiener se apresenta com similaridade significativa em relação ao sinal filtrado pelo filtro *Moving Average*. A Figura 5.5 ilustra o sinal filtrado pelo filtro de Wiener.

Figura 5.5 – Filtragem simples do espectro de supernova pelo Filtro de Wiener



Fonte: Produção do Autor.


Se sobressai o desempenho do filtro de Savitzky-Golay em relação aos outros filtros, pois a filtragem feita para este filtro engloba todos os parâmetros de qualidade:

- deslocamento mínimo dos comprimentos de onda do sinal original;
- manutenção da forma original do sinal;
- atenuação do ruído no sinal;
- a qualidade da busca de gradientes relacionada aos mínimos e máximos locais.

Entretanto, apenas uma filtragem simples não é suficiente para remover resíduos e mínimos ou máximos locais localizados em regiões ruidosas do sinal. As figuras 5.6 e 5.7 ilustram uma região ruidosa do sinal e como a


filtragem simples pelo filtro de Savitzky-Golay reduz a quantidade de ruído desta região. A Figura 5.6 ilustra a região ruidosa do sinal original, enquanto que a Figura 5.7 ilustra a região ruidosa do sinal filtrado.

Figura 5.6 – Região ruidosa do sinal original



Fonte: Produção do Autor.

Figura 5.7 – Região ruidosa do sinal filtrado pelo filtro de Savitzky-Golay



Fonte: Produção do Autor.

A filtragem simples pelo filtro de Savitzky-Golay permitiu a localização de picos e vales em regiões em que estas características não aparecem, desta maneira, é observado que apenas a filtragem simples não é suficiente para eliminar estes resíduos que interferem na análise do espectro de supernova. Esta interferência é observada na análise das linhas de emissão e de absorção que na verdade são caracterizadas como ruído, desta maneira a imprecisão gerada neste processo é propagada para toda a análise do sistema. Neste sentido, foi desenvolvida a filtragem dupla, para eliminar estas inconsistências gerando assim um processo de otimização. A tabela 5.10 indica o desempenho dos filtros no sistema de filtragem dupla, em que o sinal filtrado é a entrada para uma nova filtragem. O filtro não muda, ou seja, o sinal original é filtrado duas vezes pelo mesmo filtro com os mesmos parâmetros descritos anteriormente.

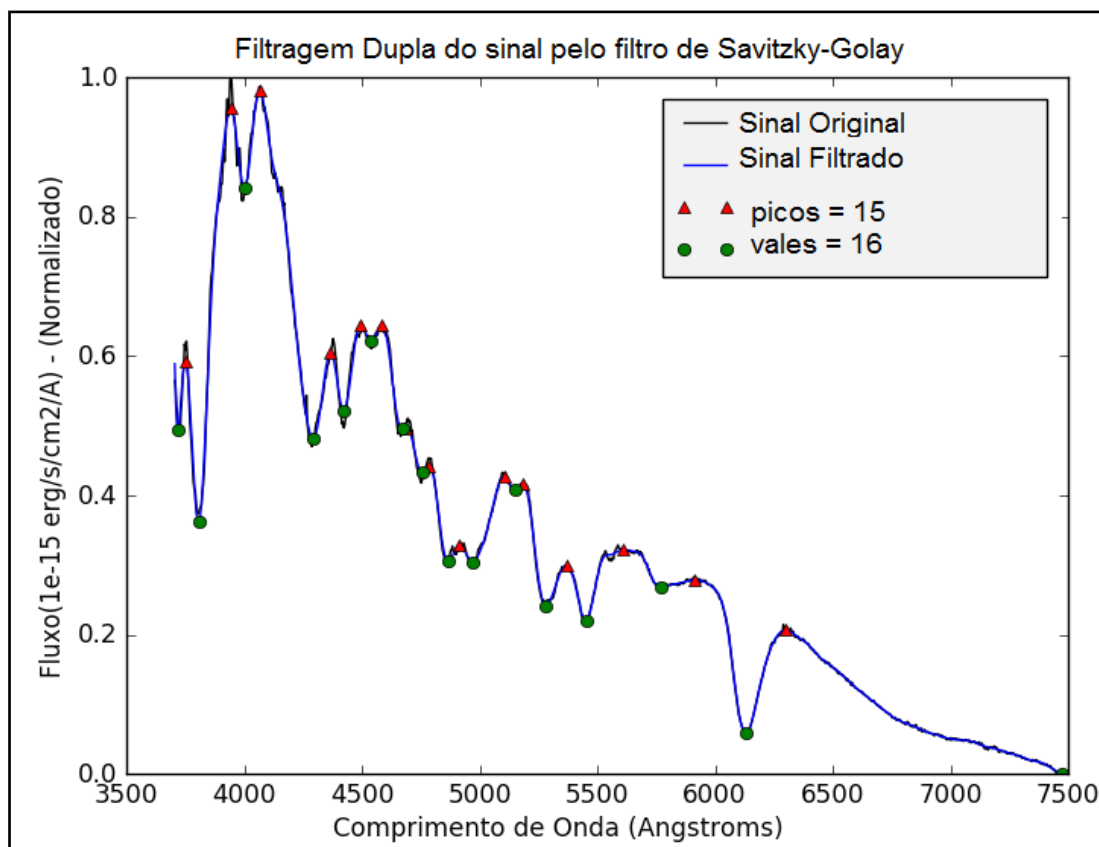
Tabela 5.10 – Desempenho dos filtros no sistema de filtragem Dupla para o sinal de Supernova SN 1998aq, com o ruído inerente ao fenômeno.

Parâmetros de Eficiência	Filtro de Savitzky-Golay	Filtro <i>Moving Average</i>	Filtro de Wiener
SNR [dB]	1.306	1.335	1.381
MSE	5.599e-05	7.886e-4	3.673e-3
RMSE	7.483e-3	2.808e-2	6.060e-2
Correlação de <i>Spearman</i>	0.999513	0.994451	0.973393
Correlação de <i>Pearson</i>	0.999546	0.993752	0.971421
Correlação Cruzada	0.999832	0.997665	0.989450
Distancia Entre os Sinais	4.538e-4	6.247e-3	2.857e-2
Deslocamento [angstroms]	0.0	0.0	3.0
Quantidade de Picos	15	8	5
Quantidade de Vales	16	8	4

Fonte: Produção do autor.

O desempenho da dupla filtragem pelo filtro de Savitzky-Golay mantém as características do sinal original, isto é evidente nos índices de correlação que se mantêm em 99%. O deslocamento do sinal duplamente filtrado em relação ao sinal original é ainda menor do que na filtragem simples. Observa-se também que os índices MSE e RMSE são menores do que no sinal de filtragem simples, indicando que a dupla filtragem reduz ainda mais os erros do modelo. A quantidade de vales e picos encontrados é reduzida em relação ao sinal na filtragem simples. A Figura 5.8 ilustra o sinal duplamente filtrado pelo filtro de Savitzky-Golay.

Figura 5.8 – Filtragem dupla do espectro de supernova pelo Filtro de Savitzky-Golay




Fonte: Produção do Autor.

A aplicabilidade do sistema de filtragem dupla nos filtros *Moving Average* e filtro de Wiener, não otimiza o desempenho de ambos. Aplicar a dupla filtragem nestes filtros deformou ainda mais os sinais, esta característica é notada no aumento do índice de SNR duplamente filtrados. Neste sentido,


aplicar a dupla filtragem nestes filtros não gera um bom sinal para a análise de espectros de supernovas. As figuras 5.9 e 5.10 ilustram a dupla filtragem para os filtros *Moving Average* e filtro de Wiener respectivamente.

Figura 5.9 – Filtragem dupla do espectro de supernova pelo Filtro *Moving Average*



Fonte: Produção do Autor.

Figura 5.10 – Filtragem dupla do espectro de supernova pelo Filtro de Wiener



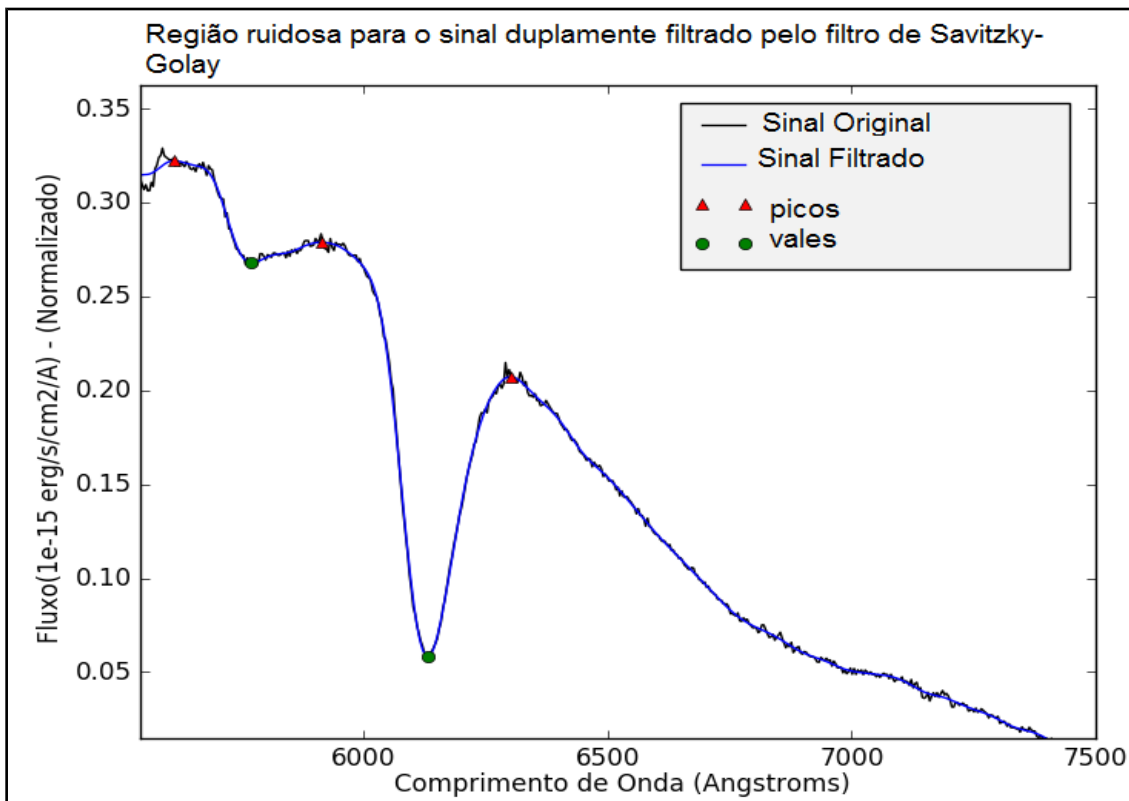
Fonte: Produção do Autor.

A filtragem dupla pelo filtro de Savitzky-Golay se sobressai sobre os outros filtros. O desempenho deste filtro é mantido em relação aos parâmetros de qualidade dos sinais:

- deslocamento mínimo dos comprimentos de onda do sinal original;
- manutenção da forma original do sinal;
- atenuação do ruído no sinal;
- a qualidade da busca de gradientes relacionada aos mínimos e máximos locais.

A otimização gerada pela dupla filtragem do filtro de Savitzky-Golay, permite a redução dos resíduos e impossibilita a localização de picos e vales no sinal em regiões ruidosas. A Figura 5.11 ilustra o desempenho desta dupla filtragem para a mesma região ruidosa do sinal ilustrada nas figuras 5.6 e 5.7. Desta vez, é observado o quanto a filtragem dupla otimiza a localização de picos e vales do sinal em relação a filtragem simples.

Figura 5.11 – Região ruidosa do sinal duplamente filtrado pelo filtro de Savitzky-Golay



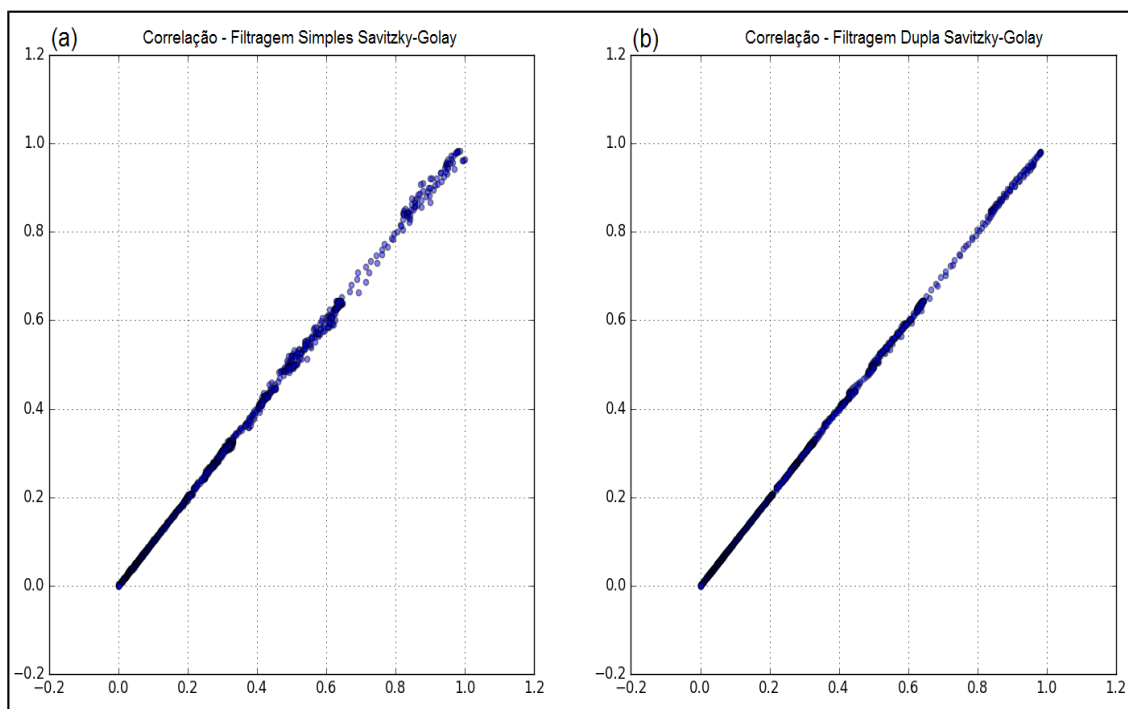
Fonte: Produção do Autor.

A aplicação do filtro de Savitzky-Golay no sistema de filtragem dupla promove a otimização na localização dos picos e vales do sinal. Ao contrário do que é observado no esquema da filtragem simples, existe a eliminação do resíduo, tornando a amostra mais coesa para a análise e abstração de parâmetros espectrais. A comparação com os outros esquemas de filtragem reside em que ponto as características importantes do sinal são mantidas.

Conforme observado, os filtros *Moving Average* e Wiener não demonstram a aplicabilidade em sinais deste tipo e embora possuam bons índices em relação a eliminação de ruído e redução de picos e vales no sinal, estes filtros não podem ser considerados para garantir os parâmetros de qualidade do sistema por gerarem deformações importantes no sinal, além da eliminação de mínimos e máximos locais importantes no sinal. Desta maneira, o sistema de filtragem dupla aplicada ao filtro de Savitzky-Golay permite a adequação a todos os parâmetros de qualidade citados.

A Figura 5.12, ilustra a correlação dos sinais em relação ao sinal original, pela filtragem simples e pela filtragem dupla, indicando o quanto o sistema de filtragem dupla mantém as características originais do sinal sem que exista o ruído, gerando um conjunto de dados homogêneo aplicável a diversos tipos de análise. Esta análise permite a observação do espectro de supernova otimizado.

Figura 5.12 – Correlação para os dados de Supernova



Onde (a) é a correlação para o sistema de filtragem simples de Savitzky-Golay e (b) é a correlação para o sistema de filtragem dupla de Savitzky-Golay

Fonte: Produção do Autor.


A abordagem construída pelo sistema de dupla filtragem mostra-se eficiente no tratamento dos sinais experimentados, proporcionando a adequação e a otimização dos parâmetros de qualidade que o sistema deve obedecer. A filtragem simples proporcionada pelo Filtro de Savitzky Golay possibilita a compreensão de bons resultados na homogeneização das amostras de dados, da suavização e do *curve-fitting*, entretanto apenas uma filtragem simples não garante a remoção completa das inconsistências e ruídos, é neste ponto que o sistema construído para este filtro no esquema de filtragem dupla otimiza os dados de tal forma a facilitar as operações de análises de cada pico ou vale existente nos espectros observando os limites de cada linha espectral para garantir a correta interpretação do sinal.

Este tipo de normalização de dados é essencial para garantir o desempenho da SUZAN na análise das qualidades de cada linha espectral evitando a análise de ruídos ou áreas distorcidas no espectro.

5.2.2 Ajuste de *Redshift*

SUZAN realiza o ajuste de *redshift* nos espectros para avaliar as linhas de emissão e absorção como se espectro estivesse em repouso. Este ajuste é feito para que as linhas espectrais de elementos de supernovas estejam ajustadas o mais próximo das linhas espectrais de elementos que são obtidas no laboratório. A Figura 5.13 ilustra o espectro da supernova SN 1998dx na sua fase de brilho máximo, indicando o espectro original sem o ajuste de *redshift* e o mesmo espectro com o ajuste de *redshift*.

Figura 5.13 – O ajuste de *Redshift* nos espectros



Fonte: Produção do Autor.

O ajuste é dado pelo valor do *redshift* (z) disponível nos bancos de espectros. A correção é feita para cada um dos espectros e é definida pela Equação 5.8 (SLOAN DIGITAL SKY SURVEY, 2017).

$$\lambda_0 = \frac{\lambda}{(z+1)} \quad (5.8)$$

Onde:

- λ_0 : comprimento de onda do objeto em repouso.
- λ : comprimento de onda observado.
- z : valor do *redshift*.

O ajuste de *redshift* é relacionado ao efeito Doppler que permite o ajuste dos comprimentos de onda do objeto de forma a indicar a observação do espectro como se o objeto estivesse em repouso (SLOAN DIGITAL SKY SURVEY, 2017).

5.2.3 Detecção de Picos e Vales no Espectro

A detecção das linhas de absorção (vales) e das linhas de emissão (picos), é feita pela localização dos mínimos e máximos locais realizando uma busca pelos gradientes. A localização foi feita utilizando a função *scipy.signal.argrelextrema* da linguagem de programação Python aplicada a análise de sinais digitais, descrita pelas Equações 5.9 e 5.10 que indicam o cálculo para a localização dos máximos e dos mínimos locais respectivamente (SCIPY, 2017).

$$pico = np.asarray(argrelextrema(fluxo, np.greater)) \quad (5.9)$$

$$vale = np.asarray(argrelextrema(fluxo, np.less)) \quad (5.10)$$

Onde:

- *pico*: representa o vetor resultante com as linhas de emissão (picos) do espectro.
- *vale*: representa o vetor resultante com as linhas de absorção (vales) do espectro.
- *fluxo*: representa os valores de fluxo do espectro.

5.2.4 Cálculo da Distância Relativa

O parâmetro de distância é definido pelo cálculo das linhas de emissão e absorção em relação a posição (comprimento de onda [Å]) das linhas de elementos encontradas em laboratório. As linhas de elementos principais utilizadas são as linhas referentes ao Hidrogênio, Silício, Enxofre e Hélio.

Estas linhas foram selecionadas de Sansonetti e Martin (2005), que contém as linhas espectrais observadas em laboratório em diferentes comprimentos de onda para os elementos neutros e uma vez ionizados da tabela periódica.

Esta comparação gera um parâmetro da menor distância entre uma linha espectral obtida do espectro de supernova avaliado e uma linha espectral obtida no laboratório, este comprimento de onda indica a proximidade da linha espectral avaliada com os tipos de elementos determinados (H, He, Si e S).

A linha espectral selecionada da supernova é comparada com todas as linhas de elementos de laboratório, retornando o módulo da subtração entre as linhas, estes resultados são guardados no vetor *dist*.

Após as subtrações serem executadas é selecionado o menor valor do vetor *dist*, este valor é a menor distância relativa à linha espectral de supernova. Este processo é repetido para todas as linhas de supernova encontradas em cada espectro. As equações 5.11 e 5.12 indicam este cálculo. Em que a função *min()* indica o menor valor obtido.

$$dist = |\lambda_{Supernova} - \lambda_{Laboratório}| \quad (5.11)$$

$$Distância = \min(dist) \quad (5.12)$$

5.2.5 Parametrização das linhas espectrais

O espectro de uma estrela é uma assinatura de sua composição atmosférica formado pelo espectro de radiação contínuo e pelas linhas de cada elemento presente, destacando a abundância de determinados elementos.

Para o caso das supernovas existe certa diferença, as linhas (sejam elas de emissão ou absorção) sofrem a influência das altas velocidades de ejeção de gás no ISM, da violência das explosões e das altíssimas temperaturas, podendo gerar linhas estreitas ou linhas largas.


A intensidade destas linhas também é variada podendo existir linhas muito intensas ou de baixa intensidade. Estes parâmetros revelam a qualidade da abundância de elementos. Desta forma, os parâmetros de Intensidade de Pico (*Peak Intensity*) e Largura Equivalente (*Equivalent Width*) abstraídos da análise do espectro são parâmetros importantes para o uso dos sistemas nebulosos, pois estes parâmetros representam informações que vão além da posição de determinada linha espectral revelando as características principais de cada linha.

Um fator determinante para o cálculo dos parâmetros é dado pelo cálculo do espectro contínuo, o espectro contínuo de um gás em equilíbrio térmico local é dado como um espectro de corpo negro e é definido conforme distribuição de Planck descrita na Equação 5.13.

$$B_{\lambda} \propto \lambda^{-5} \left[\exp\left(\frac{hc}{\lambda k_B T}\right) - 1 \right]^{-1} \quad (5.13)$$

A Figura 5.14 ilustra o espectro contínuo de corpo negro, calculado pela equação 5.13. O espectro contínuo foi obtido para um determinado espectro de uma estrela, a fim de verificar a aplicabilidade da função de Planck para determinar os parâmetros relacionados às linhas espectrais.

Figura 5.14 – Espectro contínuo de corpo negro




Fonte: Adaptado de Pierce (2013).

Pelo fato de o cálculo do espectro contínuo real ser um atributo de complexidade elevada (CHURCH, BALUCINSKA-CHURCH, 1995; ANGLADA, G. et al, 1998), e de certa forma custoso computacionalmente, SUZAN faz uma simulação para encontrar os limites superiores do ajuste das linhas espectrais, como uma forma de envelope das linhas espectrais.

A Figura 5.15 ilustra o espectro contínuo calculado pelo sistema SUZAN de forma a simular o espectro contínuo real de um espectro de supernova. Este espectro foi calculado como uma interpolação dos picos do espectro de supernova a fim de estabelecer corretamente os parâmetros de fluxo do espectro contínuo.

Figura 5.15 – Espectro contínuo simulado pelo SUZAN.



Fonte: Produção do Autor.

O cálculo do espectro de corpo negro ocorre apenas no sistema de dupla filtragem pelo filtro de Savitzky Golay, para evitar que a interpolação ocorra para dados ruidosos. Desta maneira, com o espectro contínuo calculado para cada supernova resulta no parâmetro de fluxo do espectro contínuo(F_c).

5.2.5.1 Parâmetro de Largura Equivalente

O parâmetro de Largura Equivalente define o quanto uma linha espectral, possui de área total. Este aspecto das linhas espectrais é um indicador tanto de perfil de linha como de força da linha espectral. A força de uma linha espectral é definida como forte absorção ou forte emissão de determinados elementos, isto é relacionado à abundância equivalente para cada elemento. O cálculo para este parâmetro é dado pela Equação 5.14 (COLLINS, 2003; HORVATH, 2011; POLS, 2011; PIERCE, 2013).


$$W_\lambda = \int_{\lambda_1}^{\lambda_2} \frac{F_c - F_\lambda}{F_c} d\lambda \quad (5.14)$$

Onde:

- W_λ : é o parâmetro de largura equivalente.
- λ_1, λ_2 : são os limites de cada linha no espectro.
- F_c : é o fluxo do espectro contínuo.
- F_λ : é o fluxo da linha espectral da supernova.

A Figura 5.16 ilustra a área que é obtida com o cálculo denotando como o parâmetro é calculado. A área do retângulo é equivalente a área da linha espectral.

Figura 5.16 – Largura equivalente W_λ



Fonte: Adaptado de Pierce (2013).

5.2.5.2 Parâmetro de Intensidade de Pico

De maneira similar ao parâmetro de largura equivalente o parâmetro de intensidade de pico é importante para definir a intensidade da linha espectral, de forma a dizer se uma linha, seja ela de absorção ou de emissão, possui intensidade fraca, mediana, ou forte Pierce (2013). O cálculo deste parâmetro é dado pela Equação 5.15 e é aplicável tanto para linhas de absorção como para linhas de emissão.

$$H_\lambda = F_c - F_\lambda$$

$$P = H_\lambda / F_c \quad (5.15)$$


Onde:

- H_λ : é a altura total da linha baseada nos fluxos.
- F_λ : é o fluxo da linha espectral da supernova.
- F_c : é o fluxo do espectro contínuo.
- P : é o parâmetro de intensidade de pico.

A Figura 5.17 ilustra o cálculo para o parâmetro de Intensidade de pico de acordo com o que ocorre nos espectros processados pelo sistema SUZAN, na Figura é demonstrado o calculo para linhas de absorção.

A intensidade de pico calculada para as linhas de emissão, é feita para o sinal invertido, ou seja, os fluxos são multiplicados por (-1). Desta forma, é gerado um sinal inverso e o cálculo da intensidade de pico é feito da mesma maneira como ocorre nas linhas de absorção, isto é feito pela relação que este parâmetro tem com as diferenças de altura em relação ao espectro contínuo. A Figura 5.17 ilustra o sinal para o calculo com a linha de absorção (a) e o mesmo sinal (b) onde os fluxos são multiplicados por (-1).

Figura 5.17 – Parâmetro de Intensidade de Pico



Onde (a) é o calculo da intensidade de pico para linhas de absorção e (b) é calculo da intensidade de pico para a linha de emissão.

Fonte: Produção do autor

5.3 O Conjunto de dados Gerado Para Avaliação de Supernovas

Todos os passos descritos no tratamento prévio dos espectros, foram automatizados em um programa desenvolvido em linguagem de programação Python. O programa permite que os parâmetros de todos os métodos sejam escolhidos arbitrariamente além das bases de dados submetidas à análise. Esta característica facilita a criação de uma bateria de testes que propicia o refinamento da análise além da correta escolha de parâmetros.

Os parâmetros escolhidos para o sistema de processamento de dados da

SUZAN, incluem a dupla filtragem para o filtro de Savitzky-Golay, eles são citados:

- tamanho da janela de pontos do filtro = 71;
- grau de polinômio do filtro = 9;
- interpolação linear ponto a ponto, para amostras de 1000 pontos;
- normalização de fluxos em valores entre 0~1.

Este processamento foi feito para todas as bases de dados em um sistema automático. Como saída este programa gera um arquivo para cada supernova avaliada, em que estão contidas informações sobre todas as linhas de emissão e absorção, além dos parâmetros que qualificam cada linha. A tabela 5.11 indica a disposição da saída gerada pelo processamento executado em linguagem de programação Python, esta saída compreende:

- os comprimentos de onda para as linhas de emissão e absorção de cada espectro duplamente filtrado, ou seja, são selecionadas linhas que não se caracterizam como ruído.
- o fluxo de radiação normalizado em valores de 0 a 1;
- as larguras equivalentes de cada linha espectral;
- a intensidade de pico para cada linha espectral;
- a distância relativa calculada para cada linha espectral de supernova;

Tabela 5.11 – Organização dos dados nos arquivos processados.

Comprimento de Onda [Å]	Fluxo	Largura Equivalente	Intensidade de Pico	Distância Relativa
--------------------------------	--------------	----------------------------	----------------------------	---------------------------

Fonte: Produção do autor.

Cada avaliação de supernova gera este tipo de conjunto de dados. Estes dados são utilizados como variáveis de entrada para a SUZAN na avaliação de cada supernova pelo sistema *Fuzzy*.

É importante ressaltar que a geração deste conjunto de dados é a

simplificação do conhecimento relacionado aos dados de supernova. Neste conjunto de dados são inseridas as informações de características e peculiaridades relacionadas a cada linha espectral de uma supernova, neste sentido, é válido dizer que a construção deste novo tipo de dados permite que o espectro original que *a priori* não revela suas informações sem uma interpretação específica ou análise, seja substituído pelo conjunto de dados gerado na Engenharia do Conhecimento.

Este novo conjunto de dados de supernova permite a geração de entradas para outros paradigmas de computação, tanto baseados em estatística como baseados em técnicas de inteligência artificial e aprendizado de máquina. Pois, toda análise e o conhecimento relacionado a características de cada espectro foi agregado neste conjunto.

Este tipo de dado construído para supernovas foi aplicado ao paradigma de Lógica Nebulosa, mas é possível sua aplicação em outras técnicas relacionadas a inteligência artificial:

- redes neurais artificiais;
- treinamento e reconhecimento de padrões;
- aprendizado supervisionado e não-supervisionado;
- técnicas de correlação de dados e aproximação de funções;

6 DESENVOLVIMENTO DA SUZAN

A construção do sistema para a modelagem do conhecimento do astrônomo foi feita por meio das variáveis abstraídas do espectro, estas variáveis são descritas no capítulo anterior. A partir da visualização das variáveis pôde-se construir os sistemas por meio de conjuntos de regras nebulosas que modelam as variáveis e parâmetros de acordo com o conhecimento do especialista, utilizando métodos de inferência para identificar dentre as linhas espectrais analisadas quais representam os elementos que identificam cada tipo de supernova.

Esta etapa no desenvolvimento da SUZAN foi construída em linguagem de programação JAVA em que os dados de entrada são os arquivos de supernovas gerados pelo processamento feito em linguagem de programação Python, utilizando como auxílio para a modelagem do sistema nebuloso a ferramenta *JFuzzyLogic*. A escolha pela linguagem JAVA para a programação do sistema Fuzzy, foi feita para que o sistema possuísse uma estrutura de programação orientada a objetos, desta forma garantindo o uso de classes e métodos de forma a organizar o sistema de acordo com boas práticas de programação, outro ponto importante é que a ferramenta de modelagem nebulosa *JFuzzyLogic*, adequa-se muito bem ao sistema já que foi construída para aplicabilidade em sistemas construídos em linguagem JAVA.

A ferramenta *JFuzzyLogic* é gratuita e de código aberto, ou seja, permite que o programador edite e modifique as partes do código que achar necessária além de incluir a ferramenta em qualquer aplicação desejada (CINGOLANI; ALCALA-FDEZ, 2013). Esta ferramenta enquadra-se no padrão de normas definido pelo INTERNATIONAL ELECTROTECHNICAL COMMISSION (IEC), regida pela norma IEC – 1131, que é responsável pela padronização de linguagens de programação baseada em lógica *Fuzzy* para a aplicação em controle (INTERNATIONAL ELECTROTECHNICAL COMMISSION, 1997).

As próximas seções descrevem a metodologia empregada na modelagem

nebulosa das variáveis. A seção 6.1 indica a modelagem dos termos linguísticos, das funções de pertencimento e das regras nebulosas para a avaliação de cada linha espectral conforme o conhecimento do astrônomo na avaliação do espectro. A seção 6.2 por sua vez, descreve os métodos para a análise da composição química da supernova por meio das regras nebulosas e descreve como os tipos básicos são inferidos a cada supernova explicando cada tipo de análise e os principais mecanismos para a classificação.

6.1 Construção da Avaliação de linhas de Emissão e Absorção

O modelo de classificação utilizado na construção da SUZAN foi baseado no modelo de classificação espectral, em que o astrônomo identifica no espectro as principais linhas de absorção e emissão e relaciona o elemento correspondente. Os elementos usados neste trabalho são os elementos que permitem a classificação para os tipos clássicos de supernovas: Hidrogênio, Hélio, Silício e Enxofre.


Assim como o astrônomo no momento da análise, a identificação das linhas de elementos é feita em vales (linhas de absorção) e picos (linhas de emissão). Os vales e picos escolhidos pelos astrônomos possuem uma largura, profundidade e área totais mais relevantes, logo, vales e picos sem estas características são evitados e retirados da análise. Desta forma, foi gerado um conjunto de regras nebulosas para diagnosticar quais linhas possuem as características que seriam utilizadas pelo especialista no momento da análise, permitindo que SUZAN avalie apenas as linhas interessantes ao astrônomo. Como entrada esta etapa recebe os arquivos de supernovas gerados pelo processamento da etapa de Engenharia do Conhecimento descrito no capítulo anterior.

As variáveis de entrada iniciais para a modelagem nos sistemas nebulosos são relacionadas aos parâmetros de largura equivalente e intensidade de pico. Estas variáveis são modeladas de acordo com a especialidade de um astrônomo em indicar se estes parâmetros definem uma linha espectral como

sendo mais larga ou mais estreita e possuindo intensidade baixa, média ou alta. Este tipo de modelagem também permite a identificação de linhas localizadas em declínios no espectro.

O processo de fuzzificação que é feito para as variáveis de entrada compreendem um universo de discurso no intervalo de 0 à 600 angstroms para a variável de Largura Equivalente, e de um universo de discurso no intervalo de 0 à 1 para a variável de Intensidade de Pico. A Figura 6.1 indica as funções de pertencimento e os termos linguísticos para a variável nebulosa de largura equivalente.

Figura 6.1 – Variável nebulosa de largura equivalente e termos linguísticos



Fonte: Produção do Autor

O universo de discurso para cada um dos termos linguísticos relacionados a variável nebulosa de entrada de Largura Equivalente é descrito na tabela 6.1. Indicando os termos linguísticos, o tipo de função de pertinência e o universo de discurso para cada função. Estas funções de pertinência para a variável nebulosa de Largura Equivalente são definidas como trapezoidais e triangulares, e são funções definidas para universos de discurso contínuos.


Tabela 6.1 – Fuzzificação da Variável de Largura Equivalente

Termos Linguísticos	Tipo de Função de Pertencimento	Universo de Discurso
nula	trapezoidal	$\{(0,1.0),(20,1.0),(25,0.0)\}$
pequena	trapezoidal	$\{(20,0.0),(25,1.0),(90,1.0),(100,0.0)\}$
média	trapezoidal	$\{(80,0.0),(100,1.0),(150,1.0),(200,0.0)\}$
grande	trapezoidal	$\{(180,0.0),(200,1.0),(600,1.0)\}$

Fonte: Produção do autor.

A Figura 6.2 indica as funções de pertencimento e os termos linguísticos para a variável nebulosa de Intensidade de Pico.

Figura 6.2 – Variável nebulosa de intensidade de pico e termos linguísticos



Fonte: Produção do Autor

O universo de discurso para cada um dos termos linguísticos relacionados a variável nebulosa de entrada de Intensidade de Pico é descrito na tabela 6.2. Indicando os termos linguísticos, o tipo de função de pertencimento e o universo de discurso para cada função. Estas funções de pertencimento para a variável nebulosa de Intensidade de Pico são definidas como trapezoidais e triangulares, e são funções definidas para universos de discurso contínuos.

Tabela 6.2 – Fuzzificação da Variável de Intensidade de Pico

Termos Linguísticos	Tipo de Função de Pertencimento	Universo de Discurso
nula	trapezoidal	$\{(0,1.0),(0.10,1.0),(0.15,0.0)\}$
fraca	triangular	$\{(0.13,0.0),(0.18,1.0),(0.22,0.0)\}$
mediana	triangular	$\{(0.20,0.0),(0.24,1.0),(0.35,0.0)\}$
intensa	trapezoidal	$\{(0.30,0.0),(0.35,1.0),(1.0,1.0)\}$

Fonte: Produção do autor.

A variável de saída corresponde a variável Candidato, ou seja, uma linha espectral que apresenta as características úteis no momento da análise. Estas características são referentes a: linhas largas, ou seja, *broad lines* que indicam grande abundância e intensidades de elementos; linhas em formato mediano, ou seja, com larguras e intensidades médias; e linhas estreitas, ou seja, *narrow lines*, definidas como larguras e intensidades pequenas mas não nulas.

A variável de saída para estes sistemas é definida como *singletons*, ou seja, valores constantes e seus termos linguísticos. Esta abordagem foi definida para simplificar o processo de inferência, desta maneira a saída é um número real e não um conjunto nebuloso, este tipo de inferência é relacionado ao modelo de inferência de Takagi-Sugeno de ordem zero (TAKAGI; SUGENO, 1985). Os sistemas de regras nebulosas aplicados no desenvolvimento da SUZAN possuem suas saídas como sendo números reais e desta forma, não existe o processo de defuzzificação. Os valores correspondentes as saídas constantes e seus significados linguísticos são descritos nos itens seguintes:

- nulo = 1;
- declínio = 2;
- estreito = 3;
- mediano = 4;
- largo = 5;

O conjunto de regras desenvolvido nesta etapa é demonstrado na forma do algoritmo nebuloso. O algoritmo nebuloso é composto de regras nebulosas. As regras nebulosas são afirmações condicionais que descrevem a dependência de uma ou mais variáveis em relação às outras. Cada regra nebulosa é representada por uma relação nebulosa, a inferência destas regras é dada pela agregação destas relações às regras definidas pelo método de inferência. A ativação de cada uma das regras é definida pela equação 6.1.

$$w_i = \varphi B_{1i}(\text{Largura Equivalente}) \wedge \varphi B_{2i}(\text{Intensidade de Pico}), \forall i=1, \dots, n \quad (6.1)$$

Em que B_1, \dots, B_n são os conjuntos nebulosos em função das variáveis de entrada. A ativação das regras que é dada pelo operador de implicação descrito na equação 6.1 é análogo ao operador de implicação de Mamdani (min) descrito no capítulo 3 na equação 3.10. Este operador é definido para abstrair as informações das regras nebulosas de forma a refletir a interpretação dos conectivos E, OU e CASO CONTRÁRIO (*AND, OR, ELSE*). A Figura 6.3 ilustra o algoritmo nebuloso para avaliação das linhas candidatas, este algoritmo é um conjunto de regras conjuntivas.

Figura 6.3 – Construção das regras nebulosas para análise das linhas Candidatas

REGRA 1:	SE	Largura_Equivalente	É	nula	E	Intensidade_Pico	É	nula	ENTÃO	Candidato	É	nulo;
REGRA 2:	SE	Largura_Equivalente	É	nula	E	Intensidade_Pico	É	fraca	ENTÃO	Candidato	É	nulo;
REGRA 3:	SE	Largura_Equivalente	É	nula	E	Intensidade_Pico	É	mediana	ENTÃO	Candidato	É	nulo;
REGRA 4:	SE	Largura_Equivalente	É	nula	E	Intensidade_Pico	É	intensa	ENTÃO	Candidato	É	nulo;
REGRA 5:	SE	Largura_Equivalente	É	pequena	E	Intensidade_Pico	É	nula	ENTÃO	Candidato	É	declínio;
REGRA 6:	SE	Largura_Equivalente	É	pequena	E	Intensidade_Pico	É	fraca	ENTÃO	Candidato	É	declínio;
REGRA 7:	SE	Largura_Equivalente	É	pequena	E	Intensidade_Pico	É	mediana	ENTÃO	Candidato	É	estreito;
REGRA 8:	SE	Largura_Equivalente	É	pequena	E	Intensidade_Pico	É	intensa	ENTÃO	Candidato	É	estreito;
REGRA 9:	SE	Largura_Equivalente	É	média	E	Intensidade_Pico	É	nula	ENTÃO	Candidato	É	declínio;
REGRA 10:	SE	Largura_Equivalente	É	média	E	Intensidade_Pico	É	fraca	ENTÃO	Candidato	É	estreito;
REGRA 11:	SE	Largura_Equivalente	É	média	E	Intensidade_Pico	É	mediana	ENTÃO	Candidato	É	mediano;
REGRA 12:	SE	Largura_Equivalente	É	média	E	Intensidade_Pico	É	intensa	ENTÃO	Candidato	É	mediano;
REGRA 13:	SE	Largura_Equivalente	É	grande	E	Intensidade_Pico	É	nula	ENTÃO	Candidato	É	declínio;
REGRA 14:	SE	Largura_Equivalente	É	grande	E	Intensidade_Pico	É	fraca	ENTÃO	Candidato	É	mediano;
REGRA 15:	SE	Largura_Equivalente	É	grande	E	Intensidade_Pico	É	mediana	ENTÃO	Candidato	É	largo;
REGRA 16:	SE	Largura_Equivalente	É	grande	E	Intensidade_Pico	É	intensa	ENTÃO	Candidato	É	largo;

Fonte: Produção do autor

O modelo de inferência adotado para as saídas nebulosas no formato de variáveis *singletons*, é o modelo de Takagi-Sugeno de ordem zero. Este modelo de inferência é utilizado na construção da SUZAN para simplificar o processo de obtenção da resposta do sistema, pois esta resposta não é um conjunto nebuloso e sim um número real. O modelo de inferência de Takagi-Sugeno aplicado neste trabalho é o modelo de ordem zero, pois as saídas são valores constantes (*singletons*) e desta forma o polinômio aplicado ao modelo é de ordem zero. A equação 6.2 indica este processo de inferência para gerar uma saída real para o sistema.


$$y = \frac{\sum_{i=1}^n w_i S_i}{\sum_{i=1}^n w_i}, S \in \{nulo, declinio, estreito, mediano, largo\} \quad (6.2)$$

Onde:

- y : é o resultado da saída real do sistema;
- S_i : são as variáveis de saída, contendo o valor dos termos linguísticos;
- w_i : é peso da ativação de cada regra, obtido na equação 6.1;
- n : é o número de regras nebulosas;

Esta etapa da modelagem nebulosa é necessária para a seleção de apenas linhas espectrais candidatas a possuírem características de formato estreito, mediano e largo. Estas características permitem a observação da composição de elementos presentes no espectro para a análise da composição da atmosfera estelar. Para o trabalho com supernovas, estas linhas representam os elementos do gás que foi ejetado com violência pelas explosões. A Figura 6.4 ilustra um espectro de supernova otimizado em que as linhas passaram pela avaliação da SUZAN, destacando (círculos) apenas para as linhas consideradas importantes na análise do especialista, ou seja, as linhas candidatas de saída.

Figura 6.4 – Linhas Candidatas



Fonte: Produção do autor

Este tipo de abordagem também propicia a identificação, por meio das regras nebulosas, de declínios e descidas no espectro. Este tipo de informação é importante na avaliação do espectro de supernovas de tipo Ia que possuem característica de descidas e declínios na região do infravermelho, quando o espectro é capturado próximo ao período de brilho máximo. Entretanto, neste trabalho não foram avaliados os candidatos referentes a declínios, foram utilizados apenas os candidatos a *narrow lines*, *broad lines* e linhas medianas.

Cada arquivo de supernova após a avaliação das linhas espectrais pelo sistema *fuzzy* gera como saída um novo arquivo apenas com as linhas candidatas e suas respectivas informações:

- comprimento de onda;
- fluxo de radiação normalizado;
- largura equivalente;
- intensidade de pico;

Este novo arquivo é a entrada para a etapa de avaliação de elementos.

6.2 Análise da Composição Química de Supernovas

Esta etapa de desenvolvimento da SUZAN é executada de forma similar ao modelo feito para avaliação das características das linhas espectrais. O modelo construído para avaliação da composição química de supernovas envolveu três parâmetros:

- o comprimento de onda da linha Candidata, ou seja, o comprimento de onda das linhas selecionadas pelo modelo nebuloso de avaliação de linhas espectrais;
- parâmetro de Distância Relativa, calculado na etapa de Engenharia do Conhecimento;
- as Linhas Espectrais *Fuzzy*, ou seja, a modelagem *fuzzy* das linhas espectrais relacionadas aos elementos químicos que caracterizam as supernovas.

O comprimento das linhas espectrais Candidatas selecionadas, é utilizado para calcular o valor das distâncias relativas aos elementos obtidos em laboratório. A tabela 6.3 indica os comprimentos de onda em [Å] dos elementos selecionados para a análise química de supernovas. Estes comprimentos de onda estão condidos no “*Handbook of Basic Atomic Spectroscopic Data*” que contém os comprimentos de onda para todos os elementos da tabela periódica (SANSONETTI; MARTIN, 2005). A tabela 6.3, indica os comprimentos de onda dos elementos: Hidrogênio, Hélio, Silício e Enxofre, neutros e uma vez ionizados.

Tabela 6.3 – Linhas Espectrais de elementos utilizados no sistema SUZAN


Hidrogênio [Å]	Hélio [Å]	Silício [Å]	Enxofre [Å]
4102	4009	4128	4153
4340	4026	4131	4163
4861	4121	4622	5429
6563	4144	5868	5433
-	4388	5915	5454
-	4438	5949	5474
-	4472	5958	5510
-	4685	5979	5606
-	5876	6155	5640
-	6560	6237	5660
-	6678	6244	-
-	6867	6254	-
-	7065	6347	-
-	7281	6371	-

Fonte: Produção do autor.

Este cálculo retorna o módulo da menor distância em relação aos comprimentos de onda descritos na tabela 6.3. Desta forma estas distâncias calculadas para cada linha tornam-se um parâmetro que é modelado para se tornar uma variável de entrada nebulosa. O cálculo deste parâmetro é dado pelas Equações 5.11 e 5.12.

A variável nebulosa de Distância Relativa é definida de acordo com o conhecimento humano que define se uma linha do espectro de supernova selecionada está a uma distância longa ou curta em relação aos comprimentos de onda dos elementos da tabela 6.3. A Figura 6.5, indica esta modelagem para a variável nebulosa de Distância Relativa indicando as funções de pertencimento e os termos linguísticos.

Figura 6.5 – Variável nebulosa de Distância Relativa e termos linguísticos



Fonte: Produção do Autor

O processo de fuzzificação para variável de Distância é feito em um universo de discurso no intervalo de 0 à 125 angstroms. A tabela 6.4, indica os termos linguísticos, o tipo de função de pertinência e o universo de discurso para cada função. Estas funções de pertinência para a variável nebulosa de Distância Relativa são definidas como trapezoidais e triangulares, e são funções definidas para universos de discurso contínuos.

Tabela 6.4 – Fuzzificação da Variável de Largura Equivalente

Termos Linguísticos	Tipo de Função de Pertencimento	Universo de Discurso
muito próxima	trapezoidal	$\{(0,1.0), (10,1.0), (12,0)\}$
próxima	trapezoidal	$\{(10,0.0), (15,1.0), (25,1.0), (36,0.0)\}$
média	triangular	$\{(26,0.0), (30,1.0), (40,0.0)\}$
distante	trapezoidal	$\{(35,0.0), (43,1.0), (100,1.0), (125,1.0)\}$

Fonte: Produção do autor.

As variáveis de entrada no sistema fuzzy denominadas *linhas espectrais fuzzy*, são definidas como uma modelagem para cada linha espectral da tabela 6.3. A fuzzificação das linhas espectrais de elementos foi construída para remover o pertencimento do elemento apenas para o comprimento de

onda específico, desta maneira foi criado um intervalo em que quanto mais próximo da linha espectral maior será o grau de pertencimento da linha, desta forma é aplicada a incerteza do paradigma de lógica nebulosa nestas linhas. A tabela 6.5 indica a fuzzificação das linhas do Silício, esta é uma simplificação do que é construído para cada linha espectral de todos os elementos da tabela 6.3.

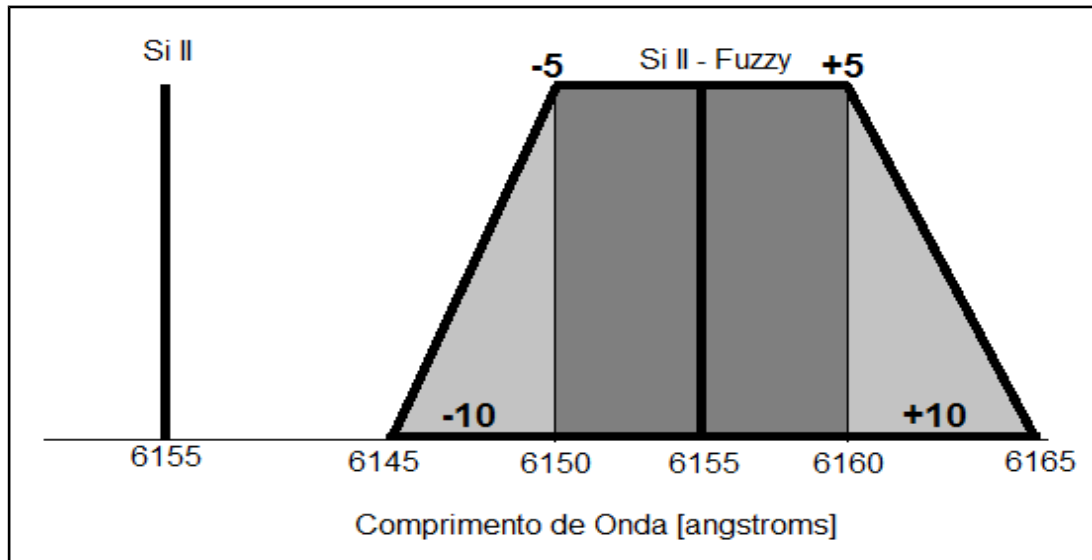
Tabela 6.5 – Linhas Espectrais de elementos utilizados no sistema SUZAN

Linhas Espectrais do Silício [Å]	Funções de Pertencimento das Linhas Espectrais Fuzzy para o Silício			
4128	{(4118,0.0),	(4123,1.0),	(4133,1.0),	(4138,0.0)}
4131	{(4121,0.0),	(4126,1.0),	(4136,1.0),	(4141,0.0)}
4622	{(4612,0.0),	(4617,1.0),	(4627,1.0),	(4632,0.0)}
5868	{(5858,0.0),	(5863,1.0),	(5873,1.0),	(5878,0.0)}
5915	{(5905,0.0),	(5910,1.0),	(5920,1.0),	(5925,0.0)}
5949	{(5939,0.0),	(5944,1.0),	(5954,1.0),	(5959,0.0)}
5958	{(5948,0.0),	(5953,1.0),	(5963,1.0),	(5968,0.0)}
5979	{(5969,0.0),	(5974,1.0),	(5984,1.0),	(5989,0.0)}
6155	{(6145,0.0),	(6150,1.0),	(6160,1.0),	(6165,0.0)}
6237	{(6227,0.0),	(6232,1.0),	(6242,1.0),	(6247,0.0)}
6244	{(6234,0.0),	(6239,1.0),	(6249,1.0),	(6254,0.0)}
6254	{(6244,0.0),	(6249,1.0),	(6259,1.0),	(6264,0.0)}
6347	{(6337,0.0),	(6342,1.0),	(6352,1.0),	(6357,0.0)}
6371	{(6361,0.0),	(6366,1.0),	(6376,1.0),	(6381,0.0)}

Fonte: Produção do autor.

As funções de pertencimento para a variável nebulosa de Linhas Espectrais *Fuzzy*, possuem um intervalo de -10 a +10 angstroms em relação ao comprimento de onda original da linha espectral, obtendo o valor de pertencimento igual a 1 no intervalo de -5 a +5 em relação a linha espectral original. A Figura 6.6 ilustra a fuzzificação de uma linha espectral, indicando o exemplo da linha para o modelo onde não existe fuzzificação e quando a fuzzificação é aplicada.

Figura 6.6 – Variável nebulosa de Linhas Espectrais Fuzzy



Fonte: Produção do Autor

A variável de saída corresponde a variável Elemento, ou seja, uma linha espectral que representa um elemento químico. Estes elementos são descritos na tabela 6.3, a variável de saída assume os valores de elementos para: Silício, Enxofre, Hidrogênio e Hélio.

Assim como é feita para a variável de saída Candidato, a variável de saída Elemento para estes sistemas é definida como um conjunto de variáveis constantes e seus significados linguísticos (*singletons*). A inferência aplicada é o modelo de Takagi-Sugeno de ordem zero e portanto não existe a defuzzificação, a saída é um número real e não um conjunto nebuloso. Os valores correspondentes as saídas constantes referentes aos elementos químicos e seus significados linguísticos são descritos nos itens seguintes:

- Hélio = 1;
- Silício = 2;
- Enxofre = 3;
- Hidrogênio = 4;
- Outro = 5;

A Figura 6.7 indica o algoritmo nebuloso para avaliação de elementos em cada linha. Quando um elemento não é identificado a variável assume o valor de Outro, ou seja, 5. O princípio básico estabelecido para este algoritmo é definido pela seguinte regra:

- Quanto menor for a distância relativa da linha espectral analisada e se esta linha estiver no intervalo correspondente às linhas espectrais *fuzzy* então esta linha pertence ao elemento correspondente. Caso contrário o elemento não identificado, ou seja, assume o valor de “Outro”.

Figura 6.7 – Algoritmo nebuloso para avaliação de elementos

```

REGRA 1: SE Linha_Espectral É SiIII E Distância Relativa É muito próxima ENTÃO elemento É Silício;
REGRA 2: SE Linha_Espectral É SiIII E Distância Relativa É próxima ENTÃO elemento É Silício;
REGRA 3: SE Linha_Espectral É SiIII E Distância Relativa É média ENTÃO elemento É Outro;
REGRA 4: SE Linha_Espectral É SiIII E Distância Relativa É distante ENTÃO elemento É Outro;
.
.
.
...

```

Fonte: Produção do Autor

A ativação de cada uma das regras é definida pela equação 6.3.

$$v_i = \varphi B_{1i}(\text{Linhas Espectrais Fuzzy}) \wedge \varphi B_{2i}(\text{Distância Relativa}), \forall i=1, \dots, n \quad (6.3)$$

Assim como na avaliação de linhas candidatas, o modelo de inferência escolhido é o Takagi-Sugeno de ordem zero. A equação 6.4 indica este processo de inferência para gerar uma saída real para o sistema.

$$y = \frac{\sum_{i=1}^n v_i K_i}{\sum_{i=1}^n v_i}, K \in \{\text{Hélio}, \text{Silício}, \text{Enxofre}, \text{Hidrogênio}, \text{Outro}\} \quad (6.4)$$

Onde:

- y : é o resultado da saída real do sistema;
- K : é a variável de saída, contendo o valor dos termos linguísticos;
- v_i : é peso da ativação de cada regra, obtido na equação 6.3;
- n : é o número de regras nebulosas;

Neste ponto SUZAN é capaz de identificar para cada supernova sua respectiva composição de elementos, neste sentido é possível avaliar os espectros e abstrair os tipos clássicos de supernovas. Estes tipos são definidos pela ausência ou presença de determinados elementos e são demonstrados no esquema de Turatto (2003). Este esquema é usado em uma árvore de decisão que verifica cada supernova identificando seu tipo como sendo Ia, Ib, Ic e II.

A análise dos elementos é segmentada em 4 intervalos de comprimento de onda em cada espectro. Estes intervalos são explicados nos itens seguintes:

- Intervalo 1: Avaliação de linhas de absorção no intervalo de 4000 a 5000 angstroms;
- Intervalo 2: Avaliação de linhas de absorção no intervalo de 5000 a 6500 angstroms;
- Intervalo 3: Avaliação de linhas de absorção no intervalo de 6500 a 7000 angstroms;
- Intervalo 4: Avaliação de linhas de emissão no intervalo de 5500 a 7000 angstroms;

Estes intervalos foram escolhidos pois as linhas críticas referentes a determinados elementos para a classificação de supernovas se encontram nestes intervalos e por isso o critério de avaliação de elementos é segmentado para emissão e absorção.

A classificação da SUZAN leva em consideração a característica do espectro no brilho máximo, seguindo o esquema proposto por Turatto (2003). Segundo Fellipenko (1997), também são observadas as características do Enxofre nas supernovas de tipo Ia, desta maneira o sistema também leva em consideração a avaliação deste elemento.

Os elementos contidos em cada espectro são avaliados seguindo uma busca pela presença ou ausência de cada elemento. Os itens seguintes indicam como estes elementos são procurados pelo SUZAN em cada espectro para gerar a classificação dos tipos de supernova:

- Tipo Ia: as supernovas do tipo Ia possuem forte presença do Silício e do Enxofre em absorção. Ausência de Hidrogênio;
- Tipo Ib: supernovas do tipo Ib indicam forte presença do Hélio em emissão e absorção e a ausência de Silício e Hidrogênio;
- Tipo Ic: ausência de Hidrogênio, Silício e Hélio;
- Tipo II: forte presença de Hidrogênio e outros elementos;

A regra de classificação é explícita em relacionar a ausência e presença de elementos e funciona para definir cada tipo de supernova. Se determinados elementos foram identificados no espectro e estes elementos estão de acordo com o esquema de classificação, logo, o espectro de supernova pertence ao tipo preestabelecido.

Este esquema de classificação permite a separação das supernovas apenas no seu período de brilho máximo, não considerando as características e abundâncias de elementos fora deste intervalo. Este esquema foi escolhido para separar com precisão as supernovas de tipo Ia no brilho máximo.

7 RESULTADOS

Os resultados da versão atual da SUZAN, são mostrados neste capítulo. Os resultados foram obtidos de acordo com os experimentos feitos para as bases de dados descritas no capítulo 5.

O desempenho é medido de acordo com a habilidade de SUZAN em separar as supernovas termonucleares, ou seja, supernovas do tipo Ia nas diversas bases de dados. Desta forma, dois tipos de classificação foram selecionados: Tipo Ia e Não Ia. Esta escolha foi feita devido ao principal motivo da classificação de supernovas Ia para estabelecer uma separação dos conjuntos com boa precisão, a identificação correta desse tipo de supernova permite a integração com outras áreas de conhecimento, como a cosmologia, astronomia e astrofísica. Desta forma, favorecendo a evolução dos estudos relacionados a expansão cósmica.

De acordo com o capítulo 5, as bases de dados são descritas como possuindo uma grande variedade de inconsistências, tanto causadas pelos variados tipos de instrumentos de coleta, quanto para a variedade dos períodos de observação.


A primeira análise descrita neste capítulo é o desempenho do sistema para as bases de dados com espectros capturados para todos os instrumentos, com diversas variações de fase espectral e variações nas escalas. Esta análise indica a imprecisão do sistema em separar corretamente as supernovas de tipo Ia no período de brilho máximo.

Os bancos originais não possuem nenhuma separação homogênea tanto de fases como de instrumentos de coleta, salvo o banco 1, em que todas as intensidades e fases são ajustadas como sendo de supernovas de tipo Ia apenas no período de brilho máximo, contendo apenas um espectro referente a um instrumento de coleta diferente. As fases espectrais dos espectros do banco 1 estão na faixa de -2.5 a +2.5 dias em relação ao espectro no brilho máximo.

A Figura 7.1 indica a observação das fases espectrais da supernova SN

1994D, as características que permitem classificar supernovas de tipo Ia próximas ao período de brilho máximo neste espectro estão nas fases de aproximadamente -6 dias (antes de atingir o máximo) a 0 dia (0, indicando o espectro no seu brilho máximo). Após este período as características mudam completamente, sendo inviável a aplicação do esquema de classificação pelos elementos químicos, pois se iniciam as fases nebulares dos espectros em +11 dias após o brilho máximo.

Figura 7.1 – Fases espectrais e dias de observação da supernova SN 1994D



Fonte: Adaptada de Blondin et al (2012).

É válido a ressalva de que os esquemas de avaliação dos dados gerados pelo sistema SUZAN são derivados da análise feita pelo especialista. Esta característica do sistema permite avaliar com clareza as supernovas no período de brilho máximo, pois é neste período que as características espectrais estão mais visíveis e distinguíveis do que nos períodos de fase nebular. E é neste período que os astrônomos inferem os tipos de supernovas clássicos pela análise espectral.

Neste capítulo, constam também os experimentos feitos para a base de dados utilizada pelo sistema CIntla de forma a comparar os acertos obtidos para a classificação de supernovas.

O capítulo também apresenta a normalização das amostras de dados para executar a análise apenas para supernovas de tipo Ia no seu período de brilho máximo. Neste sentido é provada a dupla redundância na classificação de supernovas deste tipo para os sistemas SUZAN e CIntla.

Para cada um dos experimentos foram avaliados os índices: Precisão, Acurácia Geral, *Recall* e o cálculo de *F-score*. Na estatística, o *F-score* é uma medida da precisão de um teste, este índice considera tanto a Precisão quanto o *Recall*. Para reforçar o desempenho do modelo de classificação, o cálculo para o índice Kappa também é mostrado. O coeficiente Kappa mede o acordo entre a classificação feita pelo perito humano e a classificação feita pela SUZAN. As equações (7.1; 7.2; 7.3; 7.4; 7.5) indicam os cálculos para Precisão, Acurácia geral, *Recall* e *F-score*. A equação 7.6 indica o cálculo do índice Kappa.

$$Precisão = \frac{VP}{VP + FP} \quad (7.1)$$

$$Acurácia = \frac{VP + VN}{VP + FP + FN + VN} \quad (7.2)$$

$$Recall = \frac{VP}{VP + FN} \quad (7.3)$$

$$F_{score} = 2 \times \left(\frac{Precisão \times Recall}{Precisão + Recall} \right) \quad (7.4)$$

$$Kappa = \frac{\pi_0 - \pi_e}{1 - \pi_e} \quad (7.5)$$

Onde:

- VP é o valor de verdadeiro positivo;
- VN é o valor de verdadeiro negativo;
- FP é o valor de falso positivo;
- FN é o valor de falso negativo;
- π_0 e π_e são os valores para a concordância observada e a concordância esperada respectivamente.

7.1 Resultados da SUZAN para os Bancos Originais

A performance do sistema para todos os dados agrupados é apresentada nesta seção. Esta abordagem foi construída para visualizar o desempenho do sistema em separar supernovas de tipo Ia e supernovas Não Ia para uma grande amostra de dados.

Estes bancos de dados, como descrito no capítulo 5, possuem uma grande variedade em períodos de observação dos espectros, além de conter inconsistências de escalas e intensidades em alguns espectros. Tais problemas são causados pela quantidade de instrumentos de coleta de dados utilizados.

A performance do sistema para a classificação nestes bancos de dados pode ser medida como uma condição extrema em que os dados possuem muitas

variações e não são homogêneos no que diz respeito a instrumentos, escalas, intensidades e variedades de fases. Desta forma uma avaliação de um modelo pode estar prejudicada quando aplicada a um conjunto de dados deste tipo.

A tabela 7.1 indica o desempenho na classificação dos bancos de espectros de tipo Ia e não Ia, para todas as observações dos bancos originais, ou seja, para todas as fases de supernova.

Tabela 7.1 – Resposta da SUZAN para os bancos com todos os períodos de observação

Banco	Classe	Nº de Espectros	Acertos na Classificação (%)	Espectros Classificados Corretamente
1	Ia	47	100	47
2	Ia	2603	71,91	1872
3	Ia	432	76,15	329
4	Não Ia	217	75,57	164
5	Não Ia	282	76,95	217
6	Não Ia	116	74,13	86

Fonte: Produção do autor.

A matriz de confusão para a separação de supernovas Ia e não Ia nos bancos que contém todos os períodos de observação é mostrada na tabela 7.2.

Tabela 7.2 – Matriz de confusão para classificação de Supernovas Ia e Não Ia nos bancos com todas as observações

	Tipo Ia	Tipo Não Ia
Tipo Ia	2248	834
Tipo Não Ia	148	467

Fonte: Produção do autor.

Os índices de precisão para a classificação e separação correta das supernovas Ia e não Ia nos bancos que contém todos os períodos de observação são descritos na tabela 7.3.

Tabela 7.3 – Índices de precisão para classificação de Supernovas Ia e Não Ia para todas as Observações

Precisão	Acurácia	Recall	F-Score	Kappa
0,93	0,73	0,72	0,82	0,99

Fonte: Produção do autor.

Como citado anteriormente, o desempenho para o agrupamento de todos os bancos de dados é apresentado como uma imprecisão na capacidade de separar corretamente as supernovas. Devido às variações persistentes nos bancos e a variedade nas fases de cada supernova este resultado é esperado, pois os esquemas de classificação desenvolvidos não englobam a avaliação de supernovas fora da faixa de máximo.

7.2 Desempenho da SUZAN para os Bancos utilizados pelo sistema de Classificação por Redes Neurais CIntla

Esta seção compara os resultados de classificação obtidos pela CIntla com os resultados obtidos pela SUZAN. Desta forma, avaliando os resultados obtidos na classificação produzida pela SUZAN.

Ao contrário dos bancos originais, os espectros utilizados para a classificação do sistema CIntla foram separados seguindo restrições bem específicas, de forma a eliminar as variações e inconsistências que estão presentes nos bancos originais. Os bancos utilizados pela CIntla contém a seleção de supernovas Ia e não Ia em um período de fase de -3 a +7 dias em relação ao brilho máximo, além disso são determinados limites para os comprimentos de onda dos espectros e para a dispersão espectral mínima. Neste sentido estes bancos, tem suas variações e inconsistências reduzidas no que diz respeito a escalas, fluxos e fases tornando esta amostra mais homogênea.

A tabela 7.4 indica a quantidade de espectros em cada um dos bancos, separados para o sistema CIntla contemplando espectros de supernovas apenas nos períodos de brilho máximo.

Tabela 7.4– Separação dos Bancos de espectros no CIntla

Banco	Classe	Nº de Espectros
7	Ia	560
8	Não Ia	31
9	Não Ia	44
10	Não Ia	13

Fonte: Produção do autor.

A separação dos bancos no sistema CIntla não levava em consideração as amostras dos bancos 1 e 3, desta forma, a quantidade de supernovas de tipo Ia na classificação feita pelo sistema é reduzida. A comparação para os resultados obtidos pelo CIntla é referente a avaliação do conjunto completo

feito pelo sistema SUZAN. O sistema CIntla utiliza os dados contidos na tabela 5.6, evidenciando espectros utilizados apenas para o teste da rede neural. Como os espectros da tabela de testes não foram disponibilizados foi feita uma avaliação pelo sistema SUZAN de todo o conjunto de dados utilizado, ou seja, os dados de treinamento e de teste.

Os resultados obtidos pelo sistema SUZAN com a seleção dos espectros do sistema CIntla é mostrado na tabela 7.5.

Tabela 7.5 – Resposta da SUZAN para os bancos separados no sistema CIntla

Banco	Classe	Nº de Espectros	Acertos na Classificação (%)	Espectros Classificados Corretamente
7	la	560	94,30	528
8	Não la	31	71,00	22
9	Não la	44	66,00	29
10	Não la	13	70,00	9

Fonte: Produção do autor.

A matriz de confusão para a separação de supernovas la e não la nos bancos utilizados no sistema CIntla é mostrada na tabela 7.6.

Tabela 7.6 – Matriz de confusão para classificação de Supernovas la e Não la nos bancos separados pelo sistema CIntla

	Tipo la	Tipo Não la
Tipo la	528	32
Tipo Não la	28	60

Fonte: Produção do autor.

Os índices de precisão para a classificação e separação correta das supernovas la e não la nos bancos separados pelo sistema CIntla são descritos na tabela 7.7.

Tabela 7.7 – Índices de precisão para classificação de Supernovas Ia e Não Ia para os dados do sistema CIntla

Precisão	Acurácia	Recall	F-Score	Kappa
0,95	0,90	0,94	0,95	0,99

Fonte: Produção do autor.

Os resultados obtidos com a avaliação das amostras separadas para o sistema CIntla indicam que os espectros se concentram na faixa de brilho máximo e por isso a classificação para supernovas do tipo Ia tem uma precisão de 95%, atingindo um índice de acerto de 94,3%. Os acertos gerados para a separação das supernovas de tipo não Ia, ou seja, de colapso de núcleo atingem aproximadamente 70,0% de acertos, confundindo cerca de 30% como sendo supernovas Ia. Neste sentido, a amostra de dados indica poucos exemplos de supernovas de colapso de núcleo, errando apenas 28 espectros.

Em comparação com o sistema CIntla a verificação de acertos compreende apenas o conjunto de teste e validação, descrito no capítulo 5. O sistema SUZAN por sua vez é capaz de avaliar cerca de 5 vezes mais dados do que o sistema CIntla, esta capacidade de avaliação é dependente do paradigma de inteligência artificial adotado. Em sistemas *Fuzzy* não é necessário impor um treinamento ou uma divisão nas amostras para a geração de um aprendizado de máquina. Em sistemas de regras nebulosas o conhecimento do especialista já está embutido e desta forma a análise é feita de maneira não-supervisionada.

Esta capacidade em avaliar muitos espectros permitiu que as inconsistências dos bancos de dados fossem observadas e investigadas, ampliando a visão para a variedade dos modelos de espectros de supernovas Ia e não Ia.

Esta comparação com os dados utilizados no sistema CIntla permitiu avaliar as supernovas de tipo Ia com as seguintes características:

- fase espectral de -3 a +7 dias em relação ao brilho máximo;
- comprimento de onda de 3800 a 7400 angstroms e

- dispersão espectral: menor ou igual a 1,5 angstroms por pixel.

Neste sentido, para este tipo de amostra normalizada é possível identificar corretamente as supernovas de tipo Ia no período de brilho máximo. A próxima seção indica a normalização das amostras de supernova de tipo Ia para os bancos 2 e 3 de forma a remover as inconsistências destas bases de dados e executar a análise do modelo de classificação.

7.3 Classificação de Supernovas de Tipo Ia para os Bancos 2 e 3 com Amostras Normalizadas

Para eliminar as inconsistências contidas nos bancos 2 e 3, e gerar uma separação e amostragem dos dados de supernova Ia que vai além da separação por períodos de observação foi construída uma separação por modelos de supernova no brilho máximo contidos no banco 1.

Esta separação foi criada para normalizar as amostras de dados removendo inconsistências relacionadas as variações de escala, dispersão espectral, variação nos comprimentos de onda, intensidades e fluxos de radiação.

Os modelos utilizados para a normalização de dados são pertencentes ao banco mais homogêneo da amostra de dados, o Banco 1, o qual obteve nos períodos de observação de brilho máximo 100% de acertos e precisão na classificação de supernovas de tipo Ia. Este banco foi escolhido pois, o modelo nebuloso da SUZAN conseguiu reproduzir o conhecimento do especialista, desta forma, classificando supernovas Ia com a mesma eficiência de um astrônomo. Isso indica que as regras nebulosas construídas adequam-se ao ponto de classificar as supernovas Ia com boa precisão.


As características dos espectros contidos no Banco 1 são as seguintes:

- fase espectral de -2.5 a +2.5 dias em relação ao brilho máximo;
- comprimento de onda de 3800 a 7200 angstroms;
- escala dos espectros por um fator de $1e-15$ erg/s/cm²/Å;
- a maioria dos espectros capturados pelo telescópio: FLWO 1.5m+FAST;

Foram selecionados como modelos de supernova no banco 1, 6 espectros de supernovas Ia no brilho máximo. 3 espectros continham as características clássicas do padrão desta supernova no período de brilho máximo. Os outros 3 espectros foram selecionados como espectros de supernovas Ia de brilho máximo com padrões peculiares ao modelo clássico. Estes padrões peculiares foram observados em uma plotagem para todos os dados do banco 1. Até então não havia sido observado este tipo de comportamento

nas supernovas Ia no brilho máximo. A Figura 7.2 ilustra a plotagem destes espectros, normalizados pelo sistema de dupla filtragem. Os modelos escolhidos foram obtidos do mesmo instrumento de coleta de dados, **FLWO 1.5m+FAST**, de forma a evitar as variações por instrumentos diferentes.

Figura 7.2 – Plotagem dos espectros contidos no banco 1 de supernovas Ia no brilho máximo.



Fonte: Produção do autor.

A Figura 7.2 apresenta os espectros contidos no banco 1, e que embora esteja estabelecido como um banco onde a maioria dos espectros foram coletados com um único instrumento e as fases apresentadas são pertencentes ao período de brilho máximo de supernovas de mesmo tipo, ainda se mostra com uma variedade evidente de espectros peculiares de supernovas de tipo Ia no máximo.

A tabela 7.8, indica a separação dos modelos para fazer a normalização das amostras dos bancos 2 e 3. Estes espectros selecionados são descritos pelo tipo de modelo, ou seja, supernova Ia no período de brilho máximo com o padrão clássico e supernova Ia no período de brilho máximo com o padrão peculiar. Também são descritos o nome do modelo, o nome da supernova original e instrumento de coleta destes espectros.


Tabela 7.8 – Modelos de Supernova Ia para homogenização das amostras

Tipo de Modelo de SN Ia Máximo	Nome do Modelo	Nome do Espectro Original	Instrumento de Coleta
Clássico	A-Ia_Fase1_1	sn1998dx-19980914	FLWO 1.5m+FAST
Clássico	B-Ia_Fase1_2	sn2003ch-20030328	FLWO 1.5m+FAST
Clássico	C-Ia_Fase1_3	sn1999cc-19990516	FLWO 1.5m+FAST
Peculiar 1	D-Ia_peculiar_1	sn1999ek-19991030	FLWO 1.5m+FAST
Peculiar 2	E-Ia_peculiar_2	sn1999gd-19991208	FLWO 1.5m+FAST
Peculiar 3	F-Ia_peculiar_3	sn2006gj-20060920	FLWO 1.5m+FAST

Fonte: Produção do autor.


As figuras 7.3, 7.4 e 7.5 ilustram os espectros do banco 1 selecionados como modelos clássicos. As figuras 7.6, 7.7 e 7.8 ilustram os espectros selecionados como supernovas Ia no período de brilho máximo com padrões peculiares.

Figura 7.3 – Supernova SN 1998dx modelo clássico de brilho máximo do tipo Ia: A-la_Fase1_1




Fonte: Produção do autor.

Figura 7.4 – Supernova SN 2003ch modelo clássico de brilho máximo do tipo Ia: B-la_Fase1_2




Fonte: Produção do autor.

Figura 7.5 – Supernova SN 1993cc modelo clássico de brilho máximo do tipo Ia: C-la_Fase1_3



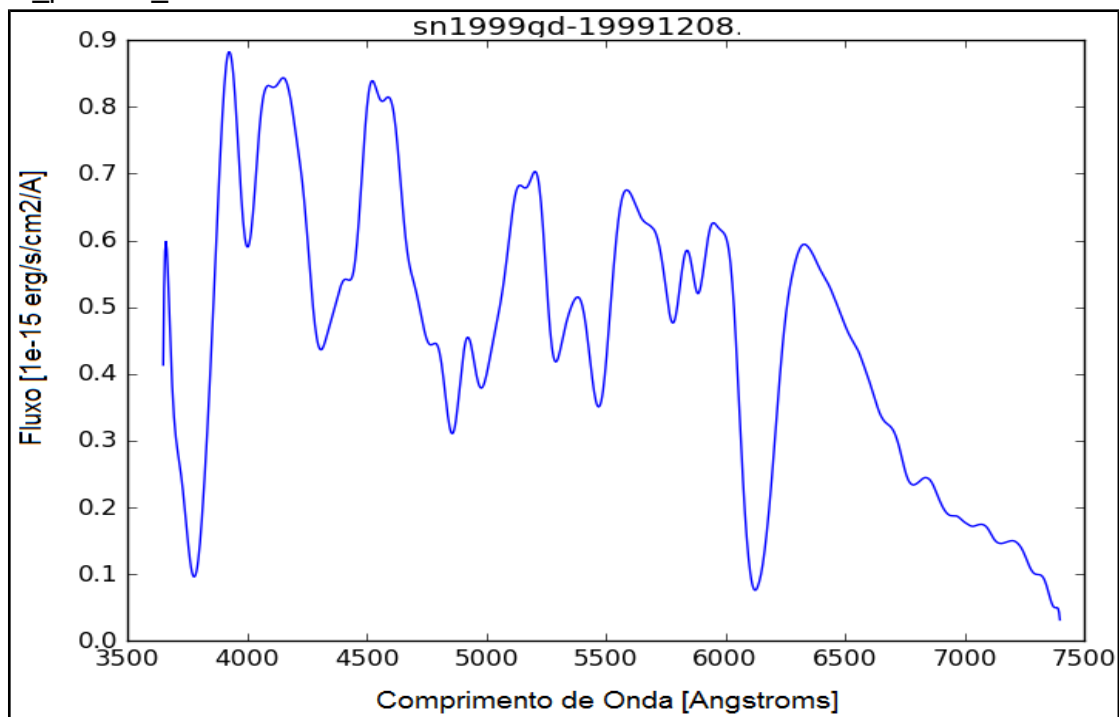
Fonte: Produção do autor.

Figura 7.6 – Supernova SN 1999ek modelo peculiar de brilho máximo do tipo Ia: D-la_peculiar_1




Fonte: Produção do autor.

Figura 7.7 – Supernova SN 1999gd modelo peculiar de brilho máximo do tipo Ia: E-la_peculiar_2



Fonte: Produção do autor.


Figura 7.8 – Supernova SN 2006gj modelo peculiar de brilho máximo do tipo Ia: F-la_peculiar_3



Fonte: Produção do autor.

Estes espectros descritos na tabela 7.8 foram separados de maneira supervisionada observando as diferenças marcantes que os tipos peculiares e clássicos apresentam. Para a avaliação deste banco também foi aplicado o algoritmo DTW (*Dynamic Time Warping*) para seleção de características de maneira não supervisionada no banco 1. Este algoritmo executa medição da similaridade entre duas séries temporais executando a melhor combinação entre os dados contidos no banco. Este algoritmo realiza um agrupamento das supernovas e o cálculo das distâncias entre cada espectro selecionando um conjunto de treinamento e teste. Após este treinamento é utilizado o algoritmo *k-means* que agrupa as amostras em conjuntos que obtiveram a melhor combinação em 4 grupos (KEOGH; RATANAMAHATANA, 2005; LIAO, 2005; MUDA; BEGAM; ELAMVAZUTHI, 2010). A Figura 7.9 indica a separação de modelos de maneira não supervisionada. Nestes modelos é evidente o aparecimento dos tipos peculiares em um dos grupos obtidos.

Figura 7.9 – Separação de modelos de supernovas Ia de brilho máximo de maneira não supervisionada



Fonte: Produção do autor.

Com os modelos selecionados foi aplicada uma correlação simples para combinar os modelos com os dados presentes nos bancos 2 e 3. O modelo de correlação escolhido foi o modelo de *Spearman*, descrito no capítulo 5 na seção sobre a dupla filtragem.

A correlação com modelos só foi possível mediante a aplicabilidade do sistema de dupla filtragem, pois não se correlacionou o ruído e sim o dado otimizado de supernova. A tabela 7.9 indica os bancos 2 e 3 normalizados com os modelos de supernovas Ia no brilho máximo.

Estes bancos são subdivididos em uma correlação com a confiança de 80%, ou seja, espectros que se correlacionaram com os modelos em índices maiores ou iguais a 80%, e a confiança de 90%, ou seja, espectros que se correlacionaram em índices maiores ou iguais a 90%.

Tabela 7.9 – Separação dos Bancos 2 e 3 com amostras normalizadas

Banco	Classe	Confiança de Correlação (%)	Nº de Espectros
2	Ia	≥ 80,00	634
3	Ia	≥ 80,00	91
2	Ia	≥ 90,00	288
3	Ia	≥ 90,00	60

Fonte: Produção do autor.

Os resultados obtidos com a separação dos espectros normalizados pelos modelos de correlação são mostrados na tabela 7.10.

Tabela 7.10 – Resposta da SUZAN para os bancos 2 e 3 para amostras normalizadas

Banco	Classe	Confiança de Correlação (%)	Nº de Espectros	Acertos na Classificação (%)	Espectros Classificados Corretamente
2	Ia	80,00	634	96,21	610
3	Ia	80,00	91	97,80	89
2	Ia	90,00	288	96,18	277
3	Ia	90,00	60	96,67	58

Fonte: Produção do autor.

Os dados de supernovas presentes nos bancos 2 e 3 são, por natureza, heterogêneos. Isto significa que existe uma variação muito grande de supernovas do mesmo tipo mas que apresentam características diferentes entre si. Desta maneira, a regra de classificação desenvolvida para espectros de supernovas perto da luz máxima, quando aplicada nestes bancos com variações grandes apresenta-se como uma imprecisão.

Quando removemos da base de dados as inconsistências, isto é, agrupamos os dados de maneira normalizada, por exemplo, o agrupamento estatístico feito para supernovas de tipo Ia no período de luz máxima (Banco 1, em que também a variedade dos instrumentos de coleta de dados é reduzida), reduzimos as inconsistências dos bancos de dados. Para os dados normalizados em relação às escalas e erros, a classificação feita pelo sistema produz bons índices de acerto, atingindo aproximadamente 98% de precisão e acurácia na classificação de supernovas de tipo Ia (Banco 3 em 80% de confiança na correlação).


A classificação, ou seja, a interpretação dos elementos contidos nos espectros chega até um determinado limite, que exclui os dados heterogêneos, pois ela só foi feita para supernovas nos modelos de brilho máximo, em certa escala e variação das intensidades definidas. Assim, para compreender todo o comportamento dos espectros de supernovas fora do período de brilho máximo é preciso agrupar e reconhecer os padrões de supernova fora desta etapa, a fim de reduzir a heterogeneidade das amostras em relação às fases de observação.

Com os novos modelos construídos é possível gerar novas regras de classificação e assim, avaliar as supernovas de maneira a compreender melhor as fases nebulares e desenvolver esquemas de classificação espectral que considerem além dos tipos a fase em que a supernova se encontra.

A variação dos instrumentos de coleta de dados também é um fator que prejudica a confiança no conjunto de dados e do desempenho do modelo. O modelo de classificação gerado no sistema SUZAN é capaz de identificar os


elementos que caracterizam as supernovas de tipo Ia, estes elementos são relacionados a forte absorção do Silício em regiões do espectro que compreendem a faixa de comprimento de onda de 6100Å e 6300Å. Neste tipo de supernova também apresentam-se as linhas do Enxofre. O sistema não consegue contornar as inconsistências geradas por instrumentos diferentes devido às diferentes interpretações que podem ser obtidas da análise do mesmo espectro. As figuras 7.10 e 7.11 ilustram a captura do espectro de supernova de tipo Ia SN 2003ch na mesma fase de observação, para dois instrumentos de coleta diferentes, os instrumentos **FLWO 1.5m+FAST** e **MMT 6.5m+Bluechannel**. Estas figuras ilustram o mesmo espectro de maneiras diferentes, de forma a indicar o quanto o instrumento de coleta influi nas características espectrais das supernovas e o quanto é importante ter uma padronização nos instrumentos de coleta, além de condicionar o modelo de análise às características de cada instrumento.

Figura 7.10 – Supernova SN 2003ch capturada pelo telescópio FLWO 1.5m+FAST



Fonte: Produção do autor.

Figura 7.11 – Supernova SN 2003ch capturada pelo telescópio MMT 6.5m+Bluechannel



Fonte: Produção do autor.

A variação nas intensidades e escalas tornam o sistema impreciso pois os sistemas nebulosos consideram os parâmetros de largura equivalente e intensidade de pico, de modo que grandes variações nas intensidades e nas escalas podem gerar imprecisões no sistema. Estas inconsistências são elevadas quando existem espectros selecionados para uma grande variedade de fases de observação, que não se enquadram nos modelos de classificação desenvolvidos pelos astrônomos especialistas.

Desta forma, a modelagem dos parâmetros para os sistemas nebulosos deve ser feita para dados coesos e obtidos para um determinado instrumento. Assim é possível modelar as regras nebulosas de acordo com as características dos dados.

As supernovas peculiares de tipo Ia no período de brilho máximo foram identificadas nos Bancos 2 e 3 e são descritas pela tabela 7.11, indicando quantos exemplos foram combinados com os 3 perfis de supernova peculiar escolhidos para os bancos correlacionados em $\geq 80,00\%$ e $\geq 90,00\%$, respectivamente.

Tabela 7.11 – Supernovas Ia peculiares encontradas nos Bancos 2 e 3 normalizados.

Banco	Classe	Confiança de Correlação (%)	Nº de Espectros
2	Ia Peculiar	≥ 80,00	153
3	Ia Peculiar	≥ 80,00	15
2	Ia Peculiar	≥ 90,00	27
3	Ia Peculiar	≥ 90,00	3

Fonte: Produção do autor.

Os espectros com perfis peculiares encontrados possuem a forte absorção do Silício e do Enxofre, e desta maneira são classificados como supernovas de tipo Ia no período de brilho máximo. Nos bancos testados não existe nenhuma informação sobre estes perfis que diferem dos modelos clássicos de supernova Ia. Assim como o astrônomo, SUZAN, avalia os elementos presentes no espectro e por isso estes espectros peculiares foram classificados como tipo Ia.

7.4 A Dupla Redundância para a Classificação de Supernovas do Tipo Ia pelos Sistemas SUZAN e CIntla

Esta seção visa estabelecer o princípio de dupla redundância nos resultados obtidos pelos dois sistemas referentes as amostras de dados. Neste sentido esta seção tem por objetivo, indicar a validação da classificação feita por dois paradigmas de inteligência artificial: a Lógica Nebulosa empregada no desenvolvimento do sistema SUZAN, e as Redes Perceptron de Múltiplas Camadas empregadas no desenvolvimento do sistema CIntla.

A Tabela 7.12 indica os espectros utilizados para esta validação dos sistemas, as bases de dados foram aplicadas nos dois sistemas e foram avaliadas as performances dos sistemas. Os Bancos indicados como B2_80% e B3_80% são as amostras normalizadas explicadas na seção anterior. Para a validação de dados estas amostras foram utilizadas por possuírem um maior número de espectros.

Tabela 7.12 – Dados utilizados nos experimentos para os dois sistemas

Banco	Tipo	Nº de Espectros nos Bancos	Espectros Avaliados pela SUZAN	Espectros Avaliados pela CIntla
1	Ia	47	47	47
2	Ia	2603	2603	2510
3	Ia	432	432	421
B2_80%	Ia	634	634	617
B3_80%	Ia	91	91	89

Fonte: Produção do autor.

A repostagem obtida pelas análises dos sistemas é calculada pela quantidade de supernovas de tipo Ia que são classificadas corretamente por cada um dos sistemas. SUZAN é um sistema que permite a inclusão e análise de espectros sem impor restrições muito rígidas, enquanto que por sua vez, CIntla devido às restrições impostas pelo treinamento exclui da análise alguns espectros. A tabela 7.13 indica a quantidade de supernovas

classificadas corretamente pelos dois sistemas, de forma a estabelecer a validação da classificação. Esta validação permite a aplicabilidade destas duas ferramentas de análise para a classificação correta de supernovas do tipo Ia. A porcentagem na classificação é medida de acordo com total de dados contidos nos bancos.

Tabela 7.13 – Tabela de validação para dupla redundância dos sistemas

Banco	Tipo	Acertos da SUZAN (nº de Espectros)	Acertos da Cintla (nº de Espectros)	Classificação SUZAN (%)	Classificação Cintla(%)
1	Ia	47	47	100,00	100,00
2	Ia	1872	1871	71,91	71,87
3	Ia	329	289	76,15	66,89
B2_80%	Ia	610	598	96,21	94,32
B3_80%	Ia	89	86	97,80	95,55

Fonte: Produção do autor.

O desempenho dos dois sistemas é prejudicado quando as amostras se apresentam com inconsistências. Entretanto, para a classificação de supernovas de tipo Ia no período de brilho máximo os dois sistemas classificam em média com uma confiança de 97,3% este tipo de supernova.

Desta maneira, se estabelece a dupla redundância dos sistemas na classificação de supernovas do tipo Ia permitindo a aplicabilidade destes dois classificadores em sistemas reais. Ainda se propõem que os dois modelos estejam acurados em relação ao tipo de dados que é produzido pelo instrumento em que será aplicado os classificadores. Desta forma os dados seriam avaliados com maior precisão já que as inconsistências seriam reduzidas, como é mostrado para as amostras contidas no Banco 1, Banco B2_80% e Banco B3_80%.

A segurança na classificação das supernovas de tipo Ia obtidas nestes dois sistemas, permite a computação das estatísticas para relacionar aos estudos da cosmologia observacional, identificando as métricas que revelam a expansão acelerada do universo.

8 CONCLUSÃO

Os resultados apresentados no capítulo 7 revelam o desempenho da SUZAN para espectros de diversas supernovas com concordância altíssima (índice Kappa). Se sobressai a análise de supernovas no brilho máximo, com índices considerados bons para supernovas do tipo Ia. Esta não é a situação para espectros observados em quantidades de tempo diferentes, pois existe a variação da forma e intensidade das linhas espectrais no decorrer do tempo, tornando a análise de espectros fora do intervalo de brilho máximo imprecisa.

O que se desenvolveu neste trabalho foi uma versão da SUZAN capaz de identificar supernovas do tipo Ia no brilho máximo, com suas fases espectrais definidas de acordo com o Banco 1, que foi modelado por especialistas para identificar e classificar supernovas no período de -2.5 a +2.5 para reproduzir um período bem próximo ao pico de luminosidade máxima da supernova. Para este banco SUZAN e Clintla, reproduzem com precisão de 100% o conhecimento do especialista para gerar a classificação das supernovas Ia.

SUZAN é um sistema robusto, pois permite analisar as supernovas de maneira geral. Entretanto, não contorna as variações contidas nos bancos de dados que são causadas principalmente pela variedade de instrumentos e calibrações diferentes.

No campo da Inteligência Artificial, o desenvolvimento e o desempenho dos algoritmos e técnicas em aprendizado de máquina deve estar alinhado a qualidade dos dados. A construção de modelos de análise mediante a escolha de conjuntos de treinamento e teste deve considerar esta premissa para que não ocorram erros na predição ou classificação dos modelos. Para isso é necessário garantir a qualidade da governança dos dados, ou seja, remover as inconsistências das amostras para gerar um modelo de predição ou classificação seguro.

Neste sentido, é sugerida uma análise prévia dos instrumentos de coleta de dados, principalmente para estabelecer uma calibração padronizada e um ajuste normalizado nas escalas e nos comprimentos de onda dos espectros

de forma a construir uma modelagem mais abrangente das regras nebulosas de acordo com os dados do instrumento calibrado. Como um dos objetivos deste trabalho envolve a aplicabilidade do sistema SUZAN ao projeto KDUST é necessária uma análise deste instrumento de coleta dos espectros e como estes espectros são dispostos, de maneira a realizar ajustes no sistema SUZAN para melhor aplicabilidade dos dados provindos do KDUST.

O conhecimento do especialista que foi modelado pelo sistema SUZAN, permitiu a identificação de linhas espectrais e suas características relacionadas a composição de elementos químicos e em quais intensidades estes elementos se apresentam. Este conhecimento também é apresentado na avaliação destas características para gerar um modelo de classificação de supernovas.

O modelo de classificação adotado pelo sistema SUZAN é baseado nos modelos de classificação adotados pelos astrônomos especialistas, desta forma a interpretação dos dados gerados pelos sistemas nebulosos é feita mediante a constatação da ausência ou presença de determinados elementos.

Foi desenvolvido um sistema capaz de classificar com a precisão de 96% supernovas de tipo Ia no período de brilho máximo, desta forma, contribuindo para o desenvolvimento de um sistema capaz de avaliar um espectro assim que a explosão da supernova ocorre. Desta maneira, é possível alavancar os estudos relacionados a expansão cósmica do universo, pois este sistema avalia uma grande quantidade de espectros de maneira automática sem qualquer necessidade da supervisão de um especialista, ou seja, este sistema pode operar de maneira autônoma e providenciar a estatística referente as supernovas Ia.

A classificação automática gerada pela SUZAN permite a detecção automática assim que a supernova explode. Esta característica permite o acompanhamento em tempo real do desenvolvimento da curva de luz da supernova, propiciando a construção de novas ferramentas de análise a fim de observar quaisquer peculiaridades envolvidas no desenvolvimento do

fenômeno. Estes pontos citados, fogem do escopo deste trabalho, entretanto sugere-se o aprofundamento das pesquisas neste trabalho para verificar estas premissas.

A avaliação do SUZAN compreendeu um universo de discurso maior do que foi avaliado para o sistema CIntla. SUZAN avalia cerca de 3697 espectros de 588 supernovas diferentes, enquanto o sistema CIntla avalia cerca de 649 espectros de 221 supernovas diferentes, desta maneira o universo de discurso da CIntla é reduzido, impossibilitando o sistema de avaliar todas as peculiaridades envolvidas no fenômeno. A classificação de supernovas de tipo Ia construídas pelo sistema CIntla considerou em seu conjunto de testes cerca de 106 espectros diferentes de supernovas de tipo Ia, SUZAN por sua vez, identificou com precisão de 96% aproximadamente 772 espectros de supernovas de tipo Ia.

Quando as amostras obtidas no sistema SUZAN foram aplicadas ao sistema CIntla, obteve-se a validação da classificação para os dois sistemas atingindo um índice de 96% de confiança na classificação de supernovas de tipo Ia. Desta forma, o objetivo de alcançar a dupla redundância na classificação, ou seja, validação dos resultados obtidos pelo sistema CIntla foi alcançado.

O desenvolvimento da SUZAN permitiu compreender que a variação nas fases das supernovas é grande e que os modelos de classificação não englobam as fases nebulares. Outro ponto importante é que o sistema SUZAN permitiu a identificação de supernovas do tipo Ia na fase de brilho máximo que são totalmente peculiares em relação ao modelo clássico.

As condições de formação destes espectros peculiares não foram avaliadas, já que não haviam informações sobre uma classificação de tipo peculiar, sobre a galáxia hospedeira ou sobre a formação do fenômeno (tipo de sistema formador, capítulo 2, seção 2.3), visto que estes espectros peculiares são visivelmente diferentes dos espectros clássicos. A única informação que foi abstraída destes espectros peculiares é a forte presença do Silício na faixa de comprimentos de onda de 6000Å a 6350Å e a forte presença do

Enxofre para faixa de comprimentos de onda de 5300Å a 5600Å.

A visualização dos espectros de supernovas la peculiares foi feita de maneira supervisionada e não supervisionada. Nas duas formas foram constadas os perfis diferentes. Neste sentido é cabível avaliar os modelos peculiares como uma variação das propriedades físicas que estão envolvidas na formação do fenômeno. Sugere-se aqui que se desenvolvam estudos de modelagem da física da explosão termonuclear em supernovas, para verificar em quais condições estes perfis peculiares se apresentam, esta investigação extrapola a condição de contorno deste trabalho.

É importante ressaltar que este sistema permite a inclusão de novas informações, ou seja, a inclusão de novos conhecimentos que levem à análise de supernova com maior refinamento. Neste ponto, SUZAN modela a capacidade humana de trabalhar com o conhecimento e agregá-lo quando necessário. Por exemplo, é possível inserir novos elementos para a análise nebulosa e outras características observadas nas linhas espectrais.

Outro ponto importante, é a contribuição do desenvolvimento do sistema de dupla filtragem no desempenho da SUZAN. A otimização gerada possibilita a aplicação para diversos tipos de sinais, pois o processamento executado é feito de forma genérica bastando apenas a escolha do filtro, a escolha dos parâmetros e a escolha do sistema de filtragem. Sem o desenvolvimento deste sistema de filtragem a redução do ruído seria impossível e consequentemente a análise das supernovas estaria prejudicada, pois as posições das linhas espectrais estariam localizadas em regiões ruidosas e seria avaliado o ruído ao invés do elemento contido na linha espectral.

Os problemas encontrados em Harutyunyan (2008) e Módolo (2016) são solucionados com esta otimização, pois é gerado um conjunto de dados homogêneo (em que não existem ajustes diferentes para cada tipo de sinal), sem ruídos e deslocamentos provindos da filtragem. Neste ponto é possível o desenvolvimento de técnicas em diversas áreas que visam a suavização de dados e a otimização do tratamento de dados.

A filtragem dupla para o filtro de Savitzky Golay proporcionou o tratamento do

espectro de supernovas de maneira automática e eficiente propiciando a análise de um sinal otimizado em que os picos e vales não se encontram em regiões ruidosas e distorcidas mas que são os picos e vales verdadeiros do sinal, esta abordagem aplicada em sistemas de classificação espectral e análise de componentes químicos em espectros de diversas bandas permite que se tenha certeza das qualidades de cada linha espectral e que estas linhas se encontram nas posições corretas, resultando de análises com a acurácia elevada do que comparado para amostras de dados com ruídos.

A partir da normalização do processamento de dados proporcionado pelo sistema de filtragem dupla é possível a construção de uma análise que possa ser reproduzida para diversos experimentos e diversos conjuntos de dados, havendo a necessidade da adequação dos dados coletados pelos instrumentos.

Em função da abordagem proporcionada e dos resultados obtidos com a pesquisa, os objetivos propostos foram atingidos. Os estudos expostos neste trabalho proporcionam contribuição no que diz respeito a classificação e ao tratamento de dados de supernovas, além de indicar a avaliação de novos perfis de supernovas existentes nas amostras de dados. Perfis estes, que não condizem com o modelo clássico e que ainda assim, devido a sua composição de elementos, foram identificados como sendo supernovas de tipo Ia no período de brilho máximo. A segurança da classificação obtida pelos dois sistemas permite alavancar estudos referentes a expansão cósmica.

8.1 Trabalhos Futuros

Os trabalhos futuros que são indicados para esta pesquisa, são relacionados a correta avaliação das fases anteriores e posteriores ao período de brilho máximo, estabelecendo para cada fase diferente um modelo de classificação para que se possa, assim como é feito pela análise da curva de luz, avaliar o espectro de um tipo de supernova em um período de tempo maior.

Neste sentido, a aplicação do modelo de dados gerado na Engenharia do

conhecimento permite que se utilize um conjunto de treinamento e de teste para redes neurais artificiais com o maior nível de abstração do conhecimento do astrônomo relacionado a espectros de supernovas.

Avaliar cada fase espectral das supernovas la como a criação de um sistema para o aprendizado destes padrões alavancaria a análise espectral a um nível em que a qualquer momento o objeto poderia ser identificado. Ou seja, aprender os perfis desta supernova antes e depois do brilho máximo permite identificar determinado espectro em muitos dias depois de sua explosão, em que é impossível coletar a curva de luz. Outro ponto importante nesta abordagem, é identificar o comportamento das supernovas la em cada uma de suas fases de forma a identificar se determinado perfil do espectro dura mais dias em algumas supernovas do que em outras e se o espectro indica se elas evoluem de maneira parecida. Neste sentido, seria possível identificar se o perfil de supernova la no brilho máximo dura mais ou menos dias de supernova para supernova.

A avaliação dos espectros sem definir como único alvo a classificação de tipo permite que se abstraia do conhecimento obtido sobre as bases de dados os parâmetros de fase espectral, de forma a garantir que a além do tipo de supernova se tenha a fase e os dias em que a explosão se encontra próximo ou distante do pico de luminosidade máxima. Desta maneira, com os dados gerados pela engenharia do conhecimento a correlação da idade da supernova permitiria avaliar os espectros de maneira automática com precisão elevada refinando além disso as informações de cada espectro.

Outra proposta interessante seria um agrupamento das características de fases nebulares que poderia ser construído por redes neurais Kohonen de maneira não supervisionada, de forma, a encontrar padrões de cada fase e ainda refinar a busca por perfis peculiares de cada supernova. O tratamento de dados proporcionado no SUZAN permite o desenvolvimento de bases de dados mais robustas para a construção de modelos de aprendizado de máquina de forma a permitir a classificação com menos inconsistências.

8.2 Publicações e Apresentações de Trabalho Realizadas Durante a Pesquisa

- ARANTES FILHO, L. R.; GUIMARÃES, L. N. F. 2017. Double Filtering System for Analysis and Processing of Supernovae Spectral Data. In: II Simpósio de Aplicações de Óptica e Lasers, 2017. São José dos Campos – SP.
- ARANTES FILHO, L. R.; GUIMARÃES, L. N. F. 2017. Spectral Analysis of Supernovae by Fuzzy Logic. In: II Simpósio de Aplicações de Óptica e Lasers, 2017. São José dos Campos – SP.
- ARANTES FILHO, L. R.; GUIMARÃES, L. N. F. Supernovae Analysis and Spectral Classification by Fuzzy Systems. In: XVII Workshop de Computação Aplicada – WORCAP 2017, 2017, São José dos Campos. XVII Workshop de Computação Aplicada – WORCAP 2017, 2017.
- ARANTES FILHO, L. R.; GUIMARÃES, L. N. F. Classificação Automática de Supernovas Utilizando Sistemas Nebulosos. (Apresentação de Trabalho/Comunicação). In: WTCIA – Workshop de Tecnologia e Ciência da Informação em Astronomia: Desafios e Propostas para a Astrofísica Brasileira, 2017.

REFERÊNCIAS BIBLIOGRÁFICAS

ABBOTT, B. P. et al. Observation of gravitational waves from a binary black hole merger. **Physical review letters**, v. 116, n. 6, p. 061102, 2016.

ANDERSON, R. **The evolution of stars: the unusual astronomy of Mass Effect, Halo, and StarCraft II**, 2012. Disponível em: <<http://kotaku.com/5924866/the-evolution-of-stars-the-unusualastronomy-of-mass-effect-halo-and-starcraft-ii>>. Acesso em: 15 dez. 2016.

ANGLADA, G. et al. Spectral indices of centimeter continuum sources in star-forming regions: Implications on the nature of the outflow exciting sources. **The Astronomical Journal**, v. 116, n. 6, p. 2953, 1998.

ARNETT, W. D. Type I supernovae. I-analytic solutions for the early part of the light curve. **The Astrophysical Journal**, v. 253, p. 785-797, 1982.

BAADE, W; ZWICKY, F. On super-novae. **Proceedings of the National Academy of Sciences**, v. 20, n. 5, p. 254-259, 1934.

BATISTA, G. E. A. P. **Pré-processamento de dados em aprendizado de máquina supervisionado**. Tese (Doutorado em Ciências da Computação e Matemática Computacional) - Universidade de São Paulo, São Paulo, 2003.

BLONDIN, S.; MANDEL, K. S.; KIRSHNER, R. P. Do spectra improve distance measurements of Type Ia supernovae? **Astronomy & Astrophysics**, v. 526, p. A81, 2011.

BLONDIN, S. et al. The spectroscopic diversity of type Ia supernovae. **The Astronomical Journal**, v. 143, n. 5, p. 126, 2012.

BLONDIN, S.; TONRY, J.L. Determining the type, redshift, and age of a supernova spectrum. **The Astrophysical Journal**, v.666, n.2, p.1024, 2007.

BRAMANTE, J. Dark matter ignition of type Ia supernovae. **Physical review letters**, v. 115, n. 14, p. 141301, 2015.

BRANCH, D. et al. Optical spectra of the type Ia supernova 1998aq. **The Astronomical Journal**, v. 126, n. 3, p. 1489, 2003.

BRANCH, D.; TAMMANN, G. A. Type Ia supernovae as standard candles. **Annual review of astronomy and astrophysics**, v. 30, n. 1, p. 359-389, 1992.

BURROWS, A.; HAYES, J.; FRYXELL, B. On the nature of core collapse supernova explosions. arXiv preprint astro-ph/9506061, 1995.

CHEN, H.L. et al. An efficient diagnosis system for detection of Parkinson's disease using fuzzy k-nearest neighbor approach. **Expert systems with applications**, v. 40, n. 1, p. 263-271, 2013.

CHEN, J. et al. New insights into the noise reduction Wiener filter. **IEEE Transactions on audio, speech, and language processing**, v. 14, n. 4, p. 1218-1234, 2006.

CHINESE CENTER FOR ANTARCTIC ASTRONOMY. **KDUST. Kunlun Dark Universe Survey Telescopes**, 2010. Disponível em: <<http://www.kdust.org/KDUST/KDUST.html>>. Acesso em: 12 abr. 2017.

CHURCH, M. J.; BALUCINSKA-CHURCH, M. A complex continuum model for the low-mass X-ray binary dipping sources: application to X 1624-49. **Astronomy and Astrophysics**, v. 300, p. 441, 1995.

CINGOLANI, P.; ALCALA-FDEZ, J. JFuzzyLogic: a robust and flexible Fuzzy-Logic inference system language implementation. In: IEEE INTERNATIONAL CONFERENCE ON FUZZY SYSTEMS, 2012. **Proceedings...** IEEE, 2012. p.1-8.

CINGOLANI, P.; ALCALÁ-FDEZ, J. JFuzzyLogic: a java library to design fuzzy logic controllers according to the standard for fuzzy control programming. **International Journal of Computational Intelligence Systems**, v. 6, n. sup1, p. 61-75, 2013.

COLLINS, G.W. II. **The fundamentals of stellar astrophysics**. 2003. Disponível em: <<http://bifrost.cwru.edu/personal/collins/astrobook/>>.

COLGATE, S. A. Neutron-star formation, thermonuclear supernovae, and heavy-element reimplosion. **The Astrophysical Journal**, v. 163, p. 221, 1971.

COSMOS. **The SAO encyclopedia of astronomy: Hertzsprung-Russell diagram**. Swinburne University of Technology. 2018. Disponível em: <<http://astronomy.swin.edu.au/cosmos/H/Hertzsprung-Russell+Diagram>>. Acesso: 15 jan. 2018.

DRUMMOND, I. N. **Uso de relações de similaridade para tratamento de consistência e cobertura em sistemas de regras difusas**. Dissertação (Mestrado em Computação Aplicada)– Instituto Nacional de Pesquisas Espaciais – INPE, São José dos Campos – SP, Brasil, 2004.

EISBERG, R.; RESNICK, R. **Física quântica**. Rio de Janeiro: Editora Campus, 1979.

FERNANDES, B. A. **Utilização do filtro de Savitzky-Golay no cancelamento de interferência de 60-Hz em sinais de eletrocardiograma**. Universidade Federal de Itajubá, 2017.

FILIPPENKO, A. V. Optical spectra of supernovae. **Annual Review of Astronomy and Astrophysics**, v. 35, n. 1, p. 309-355, 1997.

FUHRMANN, K. A thick-disc origin for Tycho Brahe's 1572 supernova? **Monthly Notices of the Royal Astronomical Society: Letters**, v. 359, n. 1, p. L35-L36, 2005.

GAMOW, G.; SCHENBERG, M. Neutrino theory of stellar collapse. **Physical Review**, v. 59, n. 7, p. 539. 1941.

GUIMARÃES, L. N. F.; SILVA, G. A. S. Desenvolvimento de controladores nebulosos para componentes de reatores nucleares. **Revista Brasileira de Pesquisa e Desenvolvimento**, v.4, p.208 – 213, 2002.

GUIMARÃES, L. N. F.; SILVA, G. A. S.; BORGES, E. M. Simulador iterativo de um gerador de vapor de tubo reto In: BRAZILIAN CONGRESS OF THERMAL ENGINEERING AND SCIENCES, 9., 2002, Caxambú - MG. **Anais...** Associação Brasileira de Ciências Mecânicas, 2002. p.1.

GUIMARÃES, L. N. F. et al. Um estudo comparativo entre técnicas de controle clássico (PI) e nebulosas (fuzzy) aplicado a um modelo de núcleo de reator PWR. In: ENCONTRO REGIONAL DE MATEMÁTICA APLICADA E COMPUTACIONAL, 2000, São José dos Campos. **Anais...** São José dos Campos: Universidade do Vale do Paraíba, 2000. p.28.

HARUTYUNYAN, A. **Automatic objective classification of supernovae.** Università Degli Studi Di Padova – Dipartimento Di Ricerca in Astronomia, 2008.

HARVARD-SMITHSONIAN CENTER FOR ASTROPHYSICS. The CfA Supernova Data Archive. The CfA Supernova Group, 2010. Disponível em: <<https://www.cfa.harvard.edu/supernova/SNarchive.html>>. Acesso em: 10 dez. 2016.

HAUKE, J.; KOSSOWSKI, T. Comparison of values of Pearson's and Spearman's correlation coefficients on the same sets of data. **Questiones geographicae**, v. 30, n. 2, p. 87-93, 2011.

HERRMANN, J. **Astronomia conhecimentos atuais.** São Paulo: Moderna, 1980.

HÖFLICH, P.; KHOKKHOLOV, A. **Explosion models for Type Ia supernovae: a comparison with observed light curves, distances, H_0 and q_0 .** arXiv preprint astro-ph/9602025, 1996.

HORNE, K. An optimal extraction algorithm for CCD spectroscopy. **Publications of the Astronomical Society of the Pacific**, v. 98, n. 604, p. 609, 1986.

HORVATH, J. E. **Fundamentos da Evolução Estelar, Supernovas e Objetos Compactos**. São Paulo: Livraria da Física, 2011.

HORVATH, J. E. et al. **Cosmologia Física do Micro ao Macro Cosmos e Vice-Versa**. São Paulo: Livraria da Física, 2011.

HORVATH, J. E. **O ABCD da Astronomia e Astrofísica**. São Paulo: Livraria da Física, 2008.

INTERNATIONAL ELECTROTECHNICAL COMMISSION. IEC 1131: programmable controllers: 7. fuzzy control programming. London, 1997.

JERKSTRAND, A. **Spectra of supernovae in the nebular phase**. arXiv preprint arXiv:1702.06702, 2017.

JHA, S. et al. UBVRI light curves of 44 type Ia supernovae. **The Astronomical Journal**, v. 131, n. 1, p. 527, 2006.

KEOGH, E.; RATANAMAHATANA, C. A. Exact indexing of dynamic time warping. **Knowledge and information systems**, v. 7, n. 3, p. 358-386, 2005.

JUANG, C. F.; LO, C. Zero-order TSK-type fuzzy system learning using a two-phase swarm intelligence algorithm. **Fuzzy Sets and Systems**, v. 159, n. 21, p. 2910-2926, 2008.

KRAUSE, O. et al. Tycho Brahe's 1572 supernova as a standard type Ia as revealed by its light-echo spectrum. **Nature**, v. 456, n. 7222, p. 617-619, 2008.

LIAO, T. W. Clustering of time series data—a survey. **Pattern recognition**, v. 38, n. 11, p. 1857-1874, 2005.

LIN, C.J. A GA-based neural fuzzy system for temperature control. **Fuzzy Sets and Systems**, v. 143, n. 2, p. 311-333, 2004.

LUO, J. et al. Properties of Savitzky–Golay digital differentiators. **Digital Signal Processing**, v. 15, n. 2, p. 122-136, 2005.

MARCH-LEUBA, C.; ABDALLA, M. A.; FORD, C. E.; GUIMARÃES, L. N. F. A Hybrid Fuzzy-PI Adaptive Control for U-Tube Steam Generator. **Control: theory and advanced technology**. v.8, p.567 – 577, 1992.

MATHESON, T. et al. Optical spectroscopy of Type Ia supernovae. **The Astronomical Journal**, v. 135, n. 4, p. 1598, 2008.

MÉNDEZ-GURROLA, I. I. et al. A knowledge based system design for the prediction of supernova effects in the interstellar environment. In: MEXICAN INTERNATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE, 6., 2007, Aguascalientes, Mexico. **Proceedings...** IEEE, 2007. p.26-35.

MODJAZ, M. et al. Optical spectra of 73 stripped-envelope core-collapse supernovae. **The Astronomical Journal**, v. 147, n. 5, p. 99, 2014.

MÓDOLO, M.; GUIMARÃES, L. N. F.; ROSA, R. R. An expert supernova spectral classification using artificial neural networks. **JCIS – Journal of Communication and Information Systems**. doi:10.6062/jcis.2015.06.02.0097. 2015.

MÓDOLO, M. **Classificação Automática de Supernovas Usando Redes Neurais Artificiais**. 2016. 233p. Tese (Doutorado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2016.

MOUSA, R.; MUNIB, Q.; MOUSSA, A. Breast cancer diagnosis system based on wavelet analysis and fuzzy-neural. **Expert systems with Applications**, v. 28, n. 4, p. 713-723, 2005.

MUDA, L.; BEGAM, M.; ELAMVAZUTHI, I. **Voice recognition algorithms using mel frequency cepstral coefficient (MFCC) and dynamic time warping (DTW) techniques**. arXiv preprint arXiv:1003.4083, 2010.

NA, M. G. Design of a genetic fuzzy controller for the nuclear steam generator water level control. **IEEE Transactions on Nuclear Science**, v. 45, n. 4, p. 2261-2271, 1998.

NEGNEVITSKY, M. **Artificial intelligence: a guide to intelligent systems**. Upper Saddle River, NJ: Pearson Education, 2005.

NIEMEYER, J. C.; WOOSLEY, S. E. The thermonuclear explosion of Chandrasekhar mass white dwarfs. **The Astrophysical Journal**, v. 475, n. 2, p. 740, 1997.

NOMOTO, K.; THIELEMANN, F.-K.; YOKOI, K. Accreting white dwarf models of Type I supernovae. III-Carbon deflagration supernovae. **The Astrophysical Journal**, v. 286, p. 644-658, 1984.

OLIVEIRA FILHO, K. S.; SARAIVA, M. F. O. **Astronomia e Astrofísica**. Porto Alegre: Universidade Federal do Rio Grande do Sul, Instituto de Física, 2014.

PERLMUTTER, S.; ALDERING, G.; GOLDHABER, G.; KNOP, R. A.; NUGENT, P.; CASTRO, P. G.; DEUSTUA, S.; FABBRO, S.; GOOBAR, A.; GROOM, D. E.; HOOK, I. M.; KIM, A. G.; KIM, M. Y.; LEE, J. C.; NUNES, N. J.; PAIN, R.; PENNYPACKER, C. R.; QUIMBY, R.; LIDMAN, C.; ELLIS, R. S.; IRWIN, M.; MCMAHON, R. G.; RUIZ-LAPUENTE, P.; WALTON, N.; SCHAEFER, B.; BOYLE, B. J.; FILIPPENKO, A. V.; MATHESON, T.; FRUCHTER, A. S.; PANAGIA, N.; NEWBERG, H. J. M.; COUCH, W. J.; PROJECT, T. S. C. Measurements of omega and lambda from 42 high-redshift supernovae. **The Astrophysical Journal**, v. 517, n. 2, p. 565, 1999. 1

PIERCE, J. N. **Notes on Stellar Astrophysics**. Edition 4.0. 2013. Disponível em: <<https://mavdisk.mnsu.edu/wp5884kt/nsa/>>

PILLAT, V.G.; FAGUNDES, P. R.; GUIMARÃES, L. N. F. Automatically identification of Equatorial Spread-F occurrence on ionograms. **Journal of Atmospheric and Solar-Terrestrial Physics**, v.135, p.115-125, 2015.

_____. Automatic analysis, identification, and classification of Equatorial Spread-F in the ionograms. In: COSMOS COSPAR, 2014, Moscow. **Proceedings...** Committee on Space Research, 2014, p.1.

PILLAT, V.G. et al. A computational tool for ionosonde CADI's ionogram analysis. **Computers & Geosciences**, v. 52, p. 372-378, n. 2013.

PILLAT, V. G. **Modelagem inteligente da análise de traços de espectros eletromagnéticos reflexivos da ionosfera, com a aplicação do paradigma de lógica nebulosa**. 2012. 119p. Tese (Doutorado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2012.

PILLAT, V.G.; GUIMARÃES, L. N. F. Identificação do perfil da ionosfera utilizando lógica nebulosa: Parte I. **Tendências em Matemática Aplicada e Computacional**, v. 15, p. 047-057, 2014.

_____. Modelo Utilizando Lógica Nebulosa na Definição de Regiões Ionosféricas nos Ionogramas. In: SIMPÓSIO BRASILEIRO DE GEOFÍSICA ESPACIAL E AERONOMIA, 3., 2010, Búzios. **Anais...** Rio de Janeiro: Sociedade Brasileira de Geofísica, 2010. p.1-1.

_____. Definição de regiões ionosféricas utilizando lógica nebulosa. In: CONGRESSO NACIONAL DE MATEMÁTICA APLICADA E COMPUTACIONAL, 2010, Águas de Lindoia, SP. **Anais...** Rio de Janeiro: Sociedade Brasileira de Matemática Aplicada e Computacional, 2010. p.1-8.

POLS, O. R. **Stellar Structure and Evolution**. Astronomical Institute Utrecht, 2011.

RIESS, A. G.; FILIPPENKO, A. V.; CHALLIS, P.; CLOCCHIATTI, A.; DIERCKS, A.; GARNAVICH, P. M.; GILLILAND, R. L.; HOGAN, C. J.; JHA, S.; KIRSHNER, R. P.; LEIBUNDGUT, B.; PHILLIPS, M. M.; REISS, D.; SCHMIDT, B. P.; SCHOMMER, R. A.; SMITH, R. C.; SPYROMILIO, J.; STUBBS, C.; SUNTZEFF, N. B.; TONRY, J. Observational evidence from supernovae for an accelerating universe and a cosmological constant. **The Astronomical Journal**, v. 116, n. 3, p. 1009, 1998. 1

RODNEY, S. A.; TONRY, J. L. Fuzzy supernova templates. I. Classification. **The Astrophysical Journal**, v. 707, n. 2, p. 1064, 2009.

RUIZ-LAPUENTE, P. et al. The binary progenitor of Tycho Brahe's 1572 supernova. **Nature**, v. 431, n. 7012, p. 1069-1072, 2004.

RUITER, A. J. et al. Delay times and rates for Type Ia supernovae and thermonuclear explosions from double-detonation sub-Chandrasekhar mass models. **Monthly Notices of the Royal Astronomical Society**, v. 417, n. 1, p. 408-419, 2011.

SANDRI, S.; CORREA, C. **Lógica nebulosa**. In: ESCOLA DE REDES NEURAI, 5., 1999, São José dos Campos, SP. **Anais...** São José dos Campos: ITA, 1999. v.5, p.73-90.

SANSONETTI, J. E.; MARTIN, W. C. **Handbook of basic atomic spectroscopic data**. Gaithersburg, Maryland: American Institute of Physics; National Institute of Standards and Technology, 2005.

SAVITZKY, A.; GOLAY, M. J. E. Smoothing and differentiation of data by simplified least squares procedures. **Analytical chemistry**, v. 36, n. 8, p. 1627-1639, 1964.

SCHAFER, R. W. What is a Savitzky-Golay filter? **IEEE Signal processing magazine**, v. 28, n. 4, p. 111-117, 2011.

SCIPY. **scipy.signal.argrextrema**. The Scipy community. 2017. Disponível em:
<<https://docs.scipy.org/doc/scipy/reference/generated/scipy.signal.argrextrema.html>>. Acesso em: 10 mar. 2017.

SILVA, G. A. S. **Análise do comportamento de modelos dinâmicos com ruído caótico, utilizando controle baseado em lógica nebulosa**. Dissertação (Mestrado em Computação Aplicada) – Instituto Nacional de Pesquisas Espaciais – INPE, São José dos Campos – SP, Brasil, 2001.

SILVA, G. A. S.; GUIMARÃES, L. N. F.; OLIVEIRA JÚNIOR, N. S. Lógica nebulosa aplicada ao controle de um gerador de vapor de tubo reto. In: ENCONTRO DE PÓS GRADUAÇÃO, 2011, São José dos Campos, SP. **Anais...** São José dos Campos: Universidade do Vale do Paraíba, 2011. v.2, p.161-165.

SILVA, G. A. S.; GUIMARÃES, L. N. F. Lógica nebulosa aplicada ao controle de um gerador de vapor de tubo reto. In: WORCAP, 2001, São José dos Campos. **Anais...** São José dos Campos: Instituto Nacional de Pesquisas Espaciais, 2001. v.1. p.57 – 59.

SIMOES, M. G.; BOSE, B. K.; SPIEGEL, R. J. Fuzzy logic based intelligent control of a variable speed cage machine wind generation system. **IEEE transactions on power electronics**, v. 12, n. 1, p. 87-95, 1997.

SLOAN DIGITAL SKY SURVEY. **SDSS. RedShifts**, 2017. Disponível em: <<http://skyserver.sdss.org/dr1/en/proj/basic/universe/redshifts.asp>>. Acesso em: 15 jan. 2017.

SUGENO, M. An introductory survey of fuzzy control. **Information sciences**, v. 36, n. 1-2, p. 59-83, 1985.

SUGENO, M.; KANG, G. T. Structure identification of fuzzy model. **Fuzzy sets and systems**, v. 28, n. 1, p. 15-33, 1988.

SULLIVAN, M. et al. Rates and properties of type Ia supernovae as a function of mass and star formation in their host galaxies. **The Astrophysical Journal**, v. 648, n. 2, p. 868, 2006.

TURATTO, M. Classification of supernovae. In: WEILER, K. W. (Ed.). *Supernovae and gamma ray busters*. Berlin: Springer, 2003. p.21-36.

TSOUKALAS, L. H.; UHRIG, R. E. **Fuzzy and neural approaches in engineering**. New York: John Wiley & Sons, 1996.

TAKAGI, T.; SUGENO, Michio. Fuzzy identification of systems and its applications to modeling and control. **IEEE transactions on systems, man, and cybernetics**, n. 1, p. 116-132, 1985.

UMEDA, H. et al. The origin of the diversity of type Ia supernovae and the environmental effects. **The Astrophysical Journal Letters**, v. 522, n. 1, p. L43, 1999.

VILLAR, A. Super-bright Supernovae are Single-Degenerate? 2015. Disponível em: <<https://astrobites.org/2015/04/07/super-bright-supernovae-are-single-degenerate/>>. Acesso em: 17 fev. 2017.

YANG, H. T.; LIAO, Chiung-Chou. Adaptive fuzzy diagnosis system for dissolved gas analysis of power transformers. **IEEE Transactions on Power Delivery**, v. 14, n. 4, p. 1342-1350, 1999.

WEAVER, K. F. et al. **Pearson's and Spearman's Correlation**. *Pearson's and spearman's correlation: an introduction to statistical analysis in research: with applications in the biological and life sciences*. New York: Wiley, 2017. p.435-471.

WILLMOTT, C. J. Some comments on the evaluation of model performance. **Bulletin of the American Meteorological Society**, v. 63, n. 11, p. 1309-1313, 1982.

WHITTLE, M. **Graduate extragalactic astronomy web notes**. 2018.

Disponível em:

<http://people.virginia.edu/~dmw8f/astr5630/Topic16/t16_SNIa_distances.html>

Acesso em: 17 fev. 2018.

ZADEH, L. A. Fuzzy sets. **Information and control**, v. 8, n. 3, p. 338-353, 1965.