

INTELIGENCIA ARTIFICIAL

http://journal.iberamia.org/

Intelligent Classification of Supernovae Using Artificial Neural Networks

Francisca Joanila Brito do Nascimento [1,A], Luis Ricardo Arantes Filho [1,B], Lamartine Nogueira Frutuoso Guimarães [1,2,C]

^[1]INPE - Instituto Nacional de Pesquisas Espaciais, São José dos Campos 12227-010, Brasil

^[2]IEAv - Instituto de Estudos Avançados, São José dos Campos 12228-001, Brasil

[A] francisca.nascimento@inpe.br, [B] luisricardoengcomp@gmail.com, [C] guimarae@ieav.cta.br

Abstract The classification of supernovae (explosions of certain stars) divides them into two main types, those of type I do not present Hydrogen in the spectrum while those of type II present. In addition to the division into these two types, there is still a subdivision that establishes types Ia, Ib and Ic. In practice, the classification of supernovae requires specialized knowledge of astronomers and data (light spectra) of good quality. Some automatic/intelligent classifiers have been developed and are reported in the literature, one of them is CIntIa, which uses 4 Artificial Neural Networks to classify supernovae types Ia, Ib, Ic and II. The objective of this work is to improve CIntIa, so that it has more diversity in its learning, proposing CIntIa 2.0. In this way, this work is a hierarchical learning structure that connects Artificial Neural Networks in an integrated system that allows a more secure and unambiguous classification. The computational improvement of this new version included the increased amount of data used at all stages of development of intelligent classifier and a new approach to filtering and processing of spectral data, ensuring better quality of information that are to be trained networks. The results achieved were good, especially in the classification of types Ia and II. A comparison with the works found in the literature shows that CIntIa 2.0 is superior in quantity and diversity of data and achieves higher classification indices than the other classifiers.

Resumo A classificação das supernovas (explosões de certas estrelas) as divide em dois tipos principais, as do tipo I não apresentam Hidrogénio no espectro enquanto as do tipo II apresentam. Além da divisão nesses dois tipos, há ainda uma subdivisão que estabelece os tipos Ia, Ib e Ic. Na prática, a classificação das supernovas exige o conhecimento especializado de astrónomos e dados (espectros de luz) de boa qualidade. Alguns classificadores automáticos/inteligentes foram desenvolvidos e são reportados na literatura, um deles é a CIntIa, que usa 4 Redes Neurais Artificiais individuais para classificar as supernovas nos tipos Ia, Ib, Ic e II. O objetivo deste trabalho é aperfeiçoar a CIntIa, a fim de que ela tenha mais diversidade em seu aprendizado, propondo a CIntIa 2.0. Dessa maneira, este trabalho propõe uma estrutura de aprendizado hierárquica que conecta as Redes Neurais Artificiais individuais em um sistema integrado permitindo uma classificação mais segura e não ambígua. O aprimoramento computacional desta nova versão compreendeu o aumento da quantidade de dados usados em todas as fases de desenvolvimento do classificador inteligente e uma nova abordagem na filtragem e processamento dos dados espectrais, garantindo mais qualidade nas informações que são submetidas ao treinamento das redes. Os resultados obtidos com este aprimoramento demonstram um bom desempenho, principalmente na classificação dos tipos Ia e II. Uma comparação com os trabalhos encontrados na literatura mostra que a CIntIa 2.0 é superior em quantidade e diversidade de dados e alcança índices de classificação superiores aos demais classificadores.

Keywords: Artificial Neural Networks, Intelligent Classification, Supernovae. **Palavras-Chave**: Redes Neurais Artificiais, Classificação Inteligente, Supernovas.

ISSN: 1137-3601 (print), 1988-3064 (on-line) ©IBERAMIA and the authors

1 Introdução

As supernovas (SNs) são grandes explosões que caracterizam o fim da vida de estrelas muito massivas. Outro mecanismo gerador de SNs é o acréscimo de massa em uma anã-branca que acontece quando ela atrai para si massa de outra estrela, sua companheira em um sistema binário. O brilho intenso das SNs tem uma grande importância nos estudos atuais de Cosmologia, por exemplo, a descoberta da expansão acelerada do Universo, que rendeu o Prêmio Nobel de Física de 2011 para os astrónomos Saul Perlmutter [23], Adam G. Riess e Brian P. Schmidt [24]. As SNs usadas na descoberta da expansão acelerada do Universo foram as do tipo Ia (SNIa), que tem a característica de manter o pico de luminosidade constante. Essa característica permite que sejam utilizadas como vela-padrão, um objeto astronómico que por sua luminosidade conhecida é usado para medir distâncias astronómicas.

Segundo [22], as SNs são classificadas em dois tipos principais propostos por Rudolph Minkowski em 1941, as SNs do tipo I não possuem Hidrogénio (H) e as do tipo II (SNII) possuem esse elemento. Há ainda uma sub-classificação do tipo I que resulta nos tipo Ia (SNIa), Ib (SNIb) e Ic (SNIc). Atualmente, a classificação de SNs segue um consenso de separar entre as de origem termonuclear e as outras, originadas do colapso do núcleo. [30] apresenta um esquema de classificação (Figura 1) que é seguido por grande parte dos classificadores automáticos e inteligentes descritos na literatura, que classificam usando a técnica da espectroscopia. Os tipos Ia, Ib, Ic e II estão destacados nos quadrados pretos e são os tipos passíveis de classificação pelo sistema CIntIa. As siglas fora dos quadrados são os elementos químicos buscados para que a classificação seja realizada: Hidrogénio (H); Silício duas vezes ionizado (Si II); e Hélio uma vez ionizado (He I). O I no quadrado branco à esquerda é o tipo I, que se subdivide nos tipos Ia, Ib e Ic. Os tipos IIb, IIL e IIP (quadrados brancos à direita), são sub-tipos do tipo II, sendo que o IIL e o IIP são diferenciados apenas pela curva de luz (fotometria). E os sub-tipos IIb pec e IIn não são considerados supernovas, mas hipernovas.

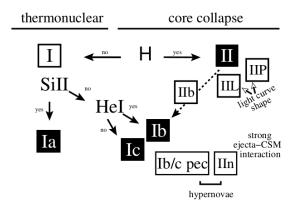


Figura 1: Esquema de classificação das SNs de acordo com os elementos químicos presentes no espectro. Os tipos Ia, Ib, Ic e II, destacados em quadrados pretos, são objectos de classificação da CIntIa. Fonte: [30].

A espectroscopia é o estudo da luz, pela sua decomposição em comprimento de ondas ou frequências (cores). Os espectros das SNIa costumam exibir picos e vales largos atribuídos aos elementos Oxigénio, Magnésio, Silício (Si), Enxofre (S), Cálcio, Ferro e Cobalto neutros ou uma vez ionizados [11]. Ainda segundo [11], os elementos Si, S, e Cálcio estão presentes principalmente na fase de máximo brilho da SN e o Ferro após essa fase, aproximadamente duas semanas depois. A fase espectral de brilho máximo é quando o brilho da SN atinge o seu valor máximo e é um período que dura apenas alguns dias. O dia em que o brilho da SN atinge o seu ápice é o dia 0, os dias precedentes tem valores negativos (a partir do -1) e os dias que sucedem esse momento tem valores positivos (a partir do +1).

O esquema de Turatto [30] foi desenvolvido considerando espectros de SNs na sua fase de máximo, isto significa que todas as características de elementos utilizadas para a classificação são aquelas que se apresentam no curto período de brilho máximo, como o Si II em espectros de SNs de tipo Ia. Destacamos

que as características espectrais, como a intensidade, a localização de picos e vales nos espectros mudam no decorrer do tempo. Essa mudança pode acarretar em classificações ambíguas, por exemplo, em SNIa a presença de linhas de elementos como o Fe I e Fe II (Ferro uma e duas vezes ionizado), bem como de Níquel e Cobalto são mais fortes e ocorrem dias após a SN atingir seu brilho máximo. Estes elementos mais complexos não são avaliados pelo esquema de Turatto, e, desta forma, a classificação torna-se difícil.

A classificação de SNs por espectroscopia, baseada na presença e ausência de elementos químicos, é normalmente rápida e pode ser feita assim que a SN é descoberta pelo telescópio, como esclarece [31]. Um dos classificadores inteligentes que usa dados espectroscópicos é a CIntIa, proposto por [21], que usa um conjunto de Redes Neurais Artificiais (RNAs) para classificar os tipos principais: Ia, Ib, Ic e II. Usar RNAs para prover classificações é vantajoso porque o sistema aprende os padrões e o aprendizado pode continuar acontecendo facilmente, em oposição a métodos puramente matemáticos. Outro classificador importante para o presente trabalho é a SUZAN, desenvolvido por [2], que utiliza lógica nebulosa e regras de aprendizado para identificar Si e S em SNs do Tipo Ia. CIntIa e SUZAN são parte de uma mesma iniciativa para fornecer sistemas de classificação automática de SNs para o projeto Kulun Dark Universe Survey Telescope (KDUST), os dois classificadores são melhor explicados na secção de Revisão Bibliográfica. O projeto KDUST está construindo um grande telescópio para o observatório de Kulun na Antártida, previsto para ser instalado em 2020 [34]. Devido a localização da estação e a grande quantidade de observações previstas para o KDUST a automatização do processo de classificação se mostra essencial. No entanto, a CIntIa e a SUZAN não estão restritas ao projeto KDUST, é possível usá-las para classificar espectros obtidos por outros telescópios. Inclusive,um classificador como a CIntIa, que usa RNAs, pode ser implementado, depois de treinado, em um sistema embarcado com custo energético muito baixo.

O objetivo deste trabalho é aperfeiçoar a CIntIa a fim de que ela tenha mais diversidade no aprendizado dos padrões de espectros de SNs Ia, principalmente, o que significa incrementar a sua capacidade de generalização. Para cumprir esse objetivo, algumas actividades, que são descritas neste artigo, foram realizadas:

- Aumento da quantidade de dados usados no treinamento e teste das RNAs. A quantidade de espectros de luz foi incrementada em mais de 1300% (de 649 para 9156);
- Aumento da amplitude de fases espectrais que podem ser reconhecidas pelo classificador. De -3 a +7 dias para -10.9 a +10.9 dias, para os espectros de SNs do tipo Ia;
- Nova abordagem na filtragem dos espectros, que utiliza o esquema de Dupla-Filtragem, o mesmo da SUZAN, proposto por [2], garantindo mais qualidade de informação;
- Desenvolvimento de uma arquitetura que integra as 4 RNAs para o aprendizado de SNs, gerando um aprendizado hierárquico e eliminando as possibilidades de classificação ambígua existente na primeira versão da CIntIa.

Com a adoção dessas medidas, a quantidade de dados passível de classificação aumentou drasticamente. Além disso, a análise dos resultados se apresenta mais robusta em relação à primeira versão da CIntIa. É importante destacar que a arquitetura para a integração das RNAs foi gerada como um resultado dos testes e dos aprimoramentos desenvolvidos para a melhoria da CIntIa 1.0.

Este artigo está organizado da seguinte maneira. Na Secção 2, explanamos o tema Supernovas e sua classificação. A Secção 3 é uma revisão da literatura de sistemas computacionais classificadores de SNs que usam espectros de luz. Em seguida, na Secção 4, tratamos dos materiais e métodos aplicados para obtenção dos resultados, que por sua vez, são apresentados na Secção 5. Finalmente, a Secção 6 apresenta a conclusão do trabalho com uma síntese do que foi realizado e as expectativas dos trabalhos futuros.

2 Supernovas

2.1 Evolução Estelar

Supernovas (SNs) são eventos caracterizados por grandes explosões que correspondem à fase final da vida de algumas estrelas. "[...] as grandes estrelas, ao sucumbir, superam galáxias inteiras em brilho. Seus clarões podem ser vistos por toda a extensão do Universo por alguns dias." [7]. Por ocorrerem apenas em

grandes estrelas, ou seja, as muito massivas, SNs são eventos raros, aproximadamente um ocorrência por galáxia a cada século, segundo [6]. Cada estrela segue uma sequência evolutiva que depende da massa que ela possui ao ser formada e se está sozinha ou em um sistema binário ou múltiplo. As estrelas com massa maior do que 10⊙ são as que geram eventos catastróficos. A Figura 2 apresenta um esquema de evolução das estrelas massivas proposto inicialmente por Peter Conti em 1976, como conta [6], e depois modificado, em todos os cenários a estrela explode marcando assim o fim de sua vida. Esse tipo de explosão é conhecido como colapso do núcleo.

$$m > 85 \mathcal{M}_{\odot}: O \longrightarrow LBV \longrightarrow WN \longrightarrow WC \longrightarrow SN$$

 $40 > m > 85 \mathcal{M}_{\odot}: O \longrightarrow WN \longrightarrow WC \longrightarrow SN$
 $25 > m > 40 \mathcal{M}_{\odot}: O \longrightarrow RSG \longrightarrow WN \longrightarrow WC \longrightarrow SN$
 $20 > m > 25 \mathcal{M}_{\odot}: O \longrightarrow RSG \longrightarrow WN \longrightarrow SN$
 $10 > m > 20 \mathcal{M}_{\odot}: OB \longrightarrow RSG \longrightarrow BSG \longrightarrow SN.$

Figura 2: Esquema de evolução das estrelas massivas. Fonte: [6].

Onde:

- LBV: Variável azul luminosa;
- WN: Tipo de estrela Wolf-Rayet que contém linhas de emissão de He e Níquel;
- WC: Tipo de estrela Wolf-Rayet que contém linhas de emissão de He e Carbono e não possui Níquel e H;
- RSG: Estrela super-gigante vermelha;
- BSG: Estrela super-gigante azul;
- OB: Estrela OB;
- SN: Supernova.

A explosão por colapso do núcleo acontece porque a estrela na sequência principal converte todo o H do núcleo em He, transformando-se em gigante. Em seguida, consome Carbono e Oxigénio passando assim à fase de super-gigante, quando consome Neônio, Magnésio e Si até restar apenas o núcleo de Ferro, as camadas da estrela são mostradas na Figura 3. Nessa etapa, a super-gigante ejecta a maior parte da sua massa originando uma SN.

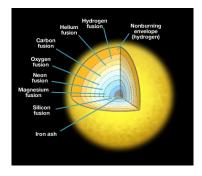


Figura 3: Camadas de uma estrela massiva. Fonte: [8].

Além das SNs originadas pelo colapso do núcleo, existem as originadas por explosões termonucleares, que são aquelas criadas em sistemas binários, onde pelo menos uma das estrelas é uma anã branca com

massa superior a $0.8\odot$. A explosão é provocada pela instabilidade no núcleo provocada pelo acréscimo de massa na anã branca, que excede o limite de Chandrasekhar $(1.38\odot)$. Segundo [33], a ignição de Carbono ou He sob condições extremamente degeneradas queima uma massa substancial no núcleo que provoca a desintegração da estrela em altas velocidades. De acordo com [22], cerca de $0.6\odot$ é ejectada ao meio interestelar na forma de Ferro, produzido durante a explosão, sendo esta a maior fonte de Ferro conhecida. Na Figura 4 somos apresentados a um esquema que mostra a evolução estelar até a explosão da SN pelos dois processos discutidos acima.

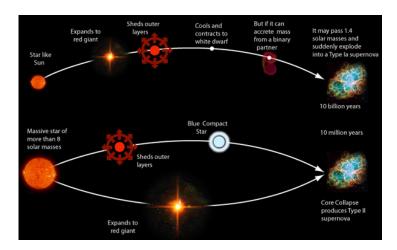


Figura 4: Evolução estelar até o estágio de SN. Fonte: [9].

2.2 Classificação das Supernovas

"As SNs são classificadas em dois tipos principais [..]: as SNs tipo I, que não apresentam H no espectro, e as SNs tipo II, que apresentam linhas de emissão ou absorção de H no espectro [...]" [22]. Segundo [6], o tipo I pode ser subdividido de acordo com seu espectro. As SNs do tipo Ia contam com uma forte presença de linhas de Si. As do tipo Ib apresentam linhas de He, enquanto as do tipo Ic não apresentam Si nem He. As SNs do tipo Ia, de acordo com [30], são as originadas das explosões termonucleares. Por outro lado, as SNs de tipo Ib, Ic e II são provenientes do colapso do núcleo das estrelas massivas. O esquema de Turatto para a classificação de SNs foi introduzido na Figura 1.

Os tipos Ia, Ib, Ic e II são os tipos que podem ser identificados a partir da análise do espectro de luz usando a técnica de espectroscopia. A espectroscopia é o estudo da luz, pela sua decomposição em comprimento de ondas ou frequências (cores). As três leis empíricas da espectroscopia foram formuladas por Gustav Kirchhoff e são postuladas como segue, segundo [22]:

- Espectro contínuo: um corpo opaco quente, sólido, líquido ou gasoso, emite um espectro contínuo;
- Espectro de emissão: um gás transparente produz um espectro de linhas brilhantes (de emissão). O número e a cor (posição) dessas linhas depende dos elementos químicos presentes no gás; e
- Espectro de absorção: se um espectro contínuo passar por um gás a temperatura mais baixa, o gás frio causa a presença de linhas escuras (absorção). O número e a posição dessas linhas depende dos elementos químicos presentes no gás.

A classificação de SNs por espectroscopia, baseada na presença e ausência de elementos químicos, é normalmente rápida e pode ser feita assim que a SN é descoberta pelo telescópio, como esclarece [31]. A Figura 5 mostra os aspectos mais comuns dos tipos principais de SNs que podem ser classificadas por espectroscopia. As regiões destacadas em cores por [20] são aquelas em que há emissão ou absorção dos elementos químicos característicos formando picos e vales. Essas regiões são as que recebem maior atenção na classificação por RNA proposta neste trabalho.

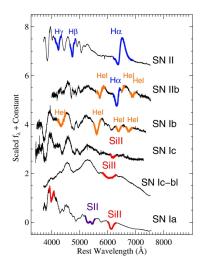


Figura 5: Padrão dos espectros de SNs dos tipos Ia, Ib, Ic, Ic-bl, II e IIb. Fonte: [20].

A fase do espectro (fase espectral) se refere ao dia, em relação ao dia em que a SN alcançou seu brilho máximo, em que aquele espectro foi auferido. O dia em que o brilho foi o mais intenso é a fase espectral 0 dias, se o espectro foi medido em dias anteriores, a fase tem valor negativo e em dias posteriores ela tem valor positivo. A fase espectral é importante para a classificação porque a forma do espectro muda com o tempo e apenas para alguns períodos existe consenso quanto à forma que o espectro de cada tipo deve ter. Por isso, a classificação automática tende a ser confiável apenas em fases mais próximas do 0 (brilho máximo) quando o padrão, principalmente para o tipo Ia, já é bem conhecido pelos especialistas. O inconveniente dessa abordagem é que é necessário traçar a curva de luz da SN para inferir a fase de cada espectro, o que pode levar alguns meses, impedindo assim a classificação rápida em plataformas semelhantes ao KDUST. Um dos avanços alcançado neste trabalho é a classificação correta de espectros em fases além do período de brilho máximo, definido na CIntIa 1.0 como -3 a +7 dias.

3 Revisão da Literatura

A classificação automática de SNs costuma ser feita de dois modos, analisando o espectro de luz (comprimento de onda em função do fluxo de radiação) ou a curvas de luz (magnitude em função do tempo). As curvas de luz permitem a análise no decorrer de 40 a 60 dias após a explosão da estrela. Em contrapartida, pode se analisar o tipo de SN pelo espectro óptico em poucos dias, no momento em que a explosão atinge o pico de luminosidade máxima [11] [4]. A classificação por espectroscopia costuma ser imediata porque a análise pode ser feita com apenas um espectro. Com dados de fotometria, a classificação só pode ser feita muitos dias depois da explosão da SN porque é necessário estabelecer o perfil temporal da intensidade do brilho. Portanto, neste trabalho, focaremos na classificação usando dados espectroscópicos. Foram selecionados 6 classificadores de SNs que usam espectro de luz para abordagem nesta secção.

3.1 Supernova Identification (SNID)

O SNID é uma ferramenta desenvolvida por [5] com a finalidade de determinar idade, redshift e classificar SNs. A identificação das SNs, que resulta em sua classificação é feita usando técnicas estatísticas. O espectro que se deseja classificar, cujo redshift deve ser conhecido, é correlacionado com outros espectros previamente identificados, o espectro recebe a mesma classificação daquele com quem mais se correlacionou. Foram usados 879 espectros de 65 SNIa, 322 de 19 SNIb/c e 353 de 10 SNII no desenvolvimento do classificador. Os espectros foram previamente pré-processados para serem submetidos à correlação com fluxo normalizado entre 0 e 1 e filtrados. Os autores consideram que o classificador alcança algum sucesso, mas os resultados não estão explícitos no trabalho.

3.2 Generic Classification Tool (GELATO)

O GELATO, apresentado por [16], é um classificador automático de SNs que pretende mitigar a subjetividade das classificações feitas por especialistas humanos. A ferramenta usa um método matemático para comparar novos espectros com outros previamente classificados em um banco de dados. Primeiramente, os espectros são pré-processados com correção do redshift, suavização, reamostragem e a divisão em 11 intervalos do comprimento de onda. A comparação entre os espectros é feita em cada um desses intervalos. A ferramenta computa para cada intervalo a distância relativa entre o novo espectro e todos os espectros do banco de dados. Por fim, calcula-se a média das distâncias relativas, o menor valor se refere ao espectro mais parecido, portanto os espectros recebem a mesma classificação. O autor relata que o GELATO é usado no dia-a-dia do seu grupo de pesquisa e que dá bons resultados, mas não são apresentadas métricas de avaliação no trabalho para comparações futuras.

3.3 Classificador Inteligente de Supernovas do tipo Ia (CIntIa 1.0)

A CIntIa 1.0 é um classificador inteligente de SNs dos tipos Ia, Ib, Ic e II e foi desenvolvida por [21]. O sistema é composto por 4 RNAs para reconhecer cada um dos tipos principais de SNs e apresenta bons resultados na classificação dos tipos, com ênfase nas SNIa.

A CIntia 1.0 usa 559 espectros de 192 SNIa, 33 espectros de 12 SNIb, 44 espectros de 12 SNIc e 13 espectros de 5 SNII, totalizando 649 espectros. Todos os espectros selecionados estão entre 3 dias antes (-3) e 7 dias depois (+7) do brilho máximo das SNs. Os espectros passam por um pré-processamento antes de serem submetidos à RNA, que inclui: correção do redshift, suavização, interpolação, e normalização do fluxo. A etapa seguinte é extrair intervalos do espectro que são usados como entradas nas RNAs. Cada intervalo corresponde a região onde se encontram ou não os elementos H, Si, S e He. As regiões escolhidas são as mais usadas pelos especialistas humanos para efetuar a classificação. Para treinar cada uma das RNAs foram selecionados 80% dos espectros, dos quais 20% são usados na validação. Foram testados 20% dos espectros, a quantidade e os resultados são apresentados na Tabela 1.

beia 1. Avanação das 4 minas que compoem o sistema Cinida 1						
	Tipo Ia	Tipo Ib	Tipo Ic	Tipo II		
Espectros testados	106	5	6	1		
Acurácia	0.99	0.97	0.97	0.98		
Precisão	0.99	1	1	0.33		
Recall	1	0.2	0.5	1		
Índice Kappa	0.95	0.32	0.65	0.49		

Tabela 1: Avaliação das 4 RNAs que compõem o sistema CIntIa 1.0.

Nessa versão da CIntIa (1.0), existe a possibilidade de um espectro de SN ser classificado de duas maneiras diferentes. Por exemplo, uma rede neural para classificar SNIa e SNIb pode classificar um espectro como sendo dos dois tipos. Dessa forma, o mesmo espectro é classificado como pertencendo a duas classes diferentes, a ambiguidade ocorre devido a falta de integração das RNAs no momento de classificar o espectro. Outra característica que procuramos melhorar neste trabalho é a confiança nos testes. A CIntIa 1.0 apresenta uma pequena quantidade de espectros testados, por exemplo, a RNA que classifica em tipo II ou tipo não-II testa apenas um espectro do tipo II. Neste trabalho, aumentamos consideravelmente a quantidade de padrões de teste, tornando assim, a análise mais segura.

3.4 Dimensionality Reduction and Clustering for Unsupervised Learning in Astronomy (DRACULA)

O DRACULA é um sistema desenvolvido por [25] para identificar subtipos do tipo Ia. Para isso o DRACULA primeiro reduz a dimensionalidade dos dados e em seguida usa aprendizado não-supervisionado para realizar a classificação. Foram usados 3677 espectros do tipo Ia na fase de redução de dimensionalidade que foi realizada com uma técnica de *Deep Learning* (DL). Espectros dentro do intervalo 4000Å a 7000Å foram inicialmente interpolados gerando espectros com 300 pontos cada. Os 300 pontos foram

transformados em apenas 4 características pelo algoritmo de DL. Em seguida, dos 3677 espectros foram selecionados 486 que foram auferidos entre -3 e +3 dias do brilho máximo das SNs. Os 486 espectros selecionados após a redução da dimensionalidade foram submetidos ao algoritmo de aprendizado não-supervisionado K-Means. O parâmetro necessário para a execução do algoritmo é o número de classes, os autores optaram por 4 classes de acordo com a divisão em subtipos do tipo Ia proposta por [32]. A classificação das SNs não ficou totalmente em acordo com a proposta de [32] e não há métricas de avaliação no trabalho suficientes para a discussão.

3.5 Quantitative Classification of Type I Supernovae

A proposta de [29] é a classificação quantitativa dos subtipos do tipo I de SNs. O método proposto pelos autores para classificar quantitativamente é medir a profundidade de linhas de absorção dos elementos Si II (em λ 6150Å) e O I (em λ 7774Å). Foram usados 146 espectros do tipo Ia, 12 do tipo Ib, 19 do tipo Ic e 4 do tipo Ib/c. As profundidades medidas resultaram em um critério desenvolvido e aplicado pelos autores para efetivar a classificação. O resultado da profundidade das regiões foi comparado com o apresentado por [27] e foi constatado que as medidas resultantes foram um pouco mais baixas do que a dos autores consultados, mas apenas 5% do total apresentaram grande discrepância, 119 medidas do Si II e 40 medidas do O I foram concordantes. Assim, os autores afirmam que a maioria das SNs do tipo I podem ser classificadas pelos critérios apresentados por eles, exceto por semelhantes à SN2002cx Ia-pec, SNs Ic-BL e as SN1991T.

3.6 Sistema Fuzzy Avaliador de Supernovas (SUZAN)

A SUZAN, apresentada por [2] é um sistema classificador de SNs que diferencia entre as SNIa e as SN não-Ia. O sistema usa lógica fuzzy e foi desenvolvido para atuar em redundância com a CIntIa. No total foram usados 3697 espectros de 588 SNs diferentes, dos quais 3082 espectros são de SNIa, 217 do tipo Ib, 282 do tipo Ic e 116 do tipo II. Os espectros passaram pela etapa de pré-processamento que consistiu na Dupla-Filtragem usando o filtro de Savitzky-Golay, ou seja, os espectros foram filtrados duas vezes seguidas e depois o redshift foi ajustado. Esta amostra de dados compreende espectros em diversas fases de observação compreendendo o intervalo de -20 dias (antes do brilho máximo da explosão) até +2959 dias (após o brilho máximo da explosão), desta forma, os espectros possuem muitas variações no decorrer do tempo.

Os elementos H, He, Si e S são buscados, então a SUZAN extrai características dos espectros para em seguida submetê-los ao crivo das regras criadas com conhecimento especialista. Primeiro, a SUZAN seleciona as linhas de emissão e absorção (linhas candidatas) que se adequam aos padrões esperados para as linhas dos elementos químicos buscados. Então, realiza-se uma nova etapa de processamento por regras fuzzy que avalia a distância relativa de cada linha candidata. Assim, ao final do processo é verificada a diversidade de elementos em cada espectro e aplicada a classificação proposta por [30]. A (Tabela 2) mostra os índices de avaliação considerando a classificação em tipo Ia ou tipo não-Ia.

Tabela 2: Métricas de avaliação da classificação entre tipo Ia e tipo não-Ia realizada pela SUZAN.

Acurácia	Precisão	Recall	F1-Score	Índice Kappa
0.73	0.93	0.72	0.82	0.34

O melhor desempenho da SUZAN acontece na classificação de espectros de SNIa na fase de brilho máximo, assim os elementos como o S e o Si são identificados pelas regras fuzzy, é neste período que os astrónomos especialistas classificam os espectros de SNIa. Dessa forma, o autor propõe uma separação de espectros de SNIa apenas na fase de brilho máximo considerando uma correlação de Spearman entre modelos de SNIa no período entre -2.5 dias a +2.5 dias, período proposto por [3] que considera ser o período em que as características do Si e do S estão mais evidentes. Foram correlacionadas 772 espectros de SNIa dos 3082 espectros originais, atingindo os índices de 96.63% na classificação entre SNIa e SN Não-Ia.

4 Materiais e Métodos

Nesta secção, são apresentados os materiais e os métodos usados neste trabalho. Tratamos das Redes Neurais Artificiais, dos bancos de espectros usados, do pré-processamento pelo qual todos os espectros foram submetidos, com ênfase na Dupla-Filtragem, da extração de características para as entradas do sistema e das configurações da CIntIa que tornaram possíveis a obtenção de resultados que são apresentados na próxima secção.

4.1 Redes Neurais Artificiais

Uma Rede Neural Artificial (RNA) é uma rede que conecta unidades de processamento simples, os neurónios (Figura 6), e tem a capacidade de aprendizado por meio de exemplos. Segundo [17], os elementos que compõem o neurónio são os seguintes:

- Peso sináptico: é um valor negativo ou positivo que representa a força de conexão entre um dado de entrada e o neurónio. O primeiro índice de um peso se refere ao neurónio e o segundo índice é o mesmo da entrada;
- Somador ou Junção Aditiva: é responsável por somar todas as entradas ponderadas por seus pesos sinápticos;
- Bias: é um fator que aumenta ou diminui o valor da saída do somador;
- Função de ativação: é a função que define a saída do neurónio.

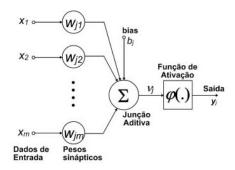


Figura 6: Modelo de um neurónio artificial. Fonte: [12].

A conexão entre mais de um neurónio molda a arquitetura de uma RNA. A ligação entre os neurónios pode ser feita em apenas uma camada, na qual as entradas são multiplicadas pelos pesos, passam pelo somador e logo em seguida pela função de ativação. Ou a RNA pode ter mais de uma camada, assim a saída de uma camada é usada como entrada para os neurónios da camada posterior sendo propagada até a saída.

O aprendizado da RNA, por sua vez, pode ser do tipo supervisionado ou não-supervisionado. No aprendizado supervisionado, em oposição ao não-supervisionado, um agente externo apresenta à RNA alguns padrões de entrada e seus correspondentes padrões de saída. Portanto, é necessário ter um conhecimento prévio do comportamento que se deseja ou se espera da rede, como esclarece [10]. O aprendizado depende de um algoritmo que modifica os pesos de acordo com as saídas da RNA em cada sessão de treinamento.

O algoritmo de atualização dos pesos, conhecido como backpropagation é o mais usado com a RNA Perceptron de Múltiplas Camadas (MLP, do inglês Multi-Layer Perceptron). Esse tipo de RNA consiste de um conjunto de unidades que constituem a camada de entrada, uma ou mais camadas ocultas (intermediárias) e uma camada de saída, como descreve [17]. "A abordagem adotada pelo algoritmo [backpropagation] consiste em iniciar na camada de saída e propagar o erro retroativamente através das

camadas ocultas." [19]. O treinamento com backpropagation usa a regra delta generalizada. O cálculo do fator delta de cada neurónio depende se o neurônio está na camada de saída ou em uma camada intermediária. As Equações 1 e 2 são as fórmulas para calcular o erro e o delta, respetivamente, em neurónios da camada de saída. Enquanto a Equação 3 é a fórmula para calcular o delta em neurónios de camadas ocultas. As equações são as mesmas apresentadas por [17].

$$e_j = d_j - y_j \tag{1}$$

Onde:

- e_i : erro no neurónio j;
- d_i: resultado esperado do neurónio j;
- y_i : resultado obtido no neurónio j.

$$\delta_j = e_j \dot{\varphi}_j(v_j) \tag{2}$$

Onde:

- δ_i : delta do neurónio j;
- e_i : erro no neurónio j;
- $\dot{\varphi}_i(v_i)$: derivada da função de ativação do neurónio j.

$$\delta_j = \dot{\varphi}_j(v_j) \sum_k \delta_k w_{kj} \tag{3}$$

Onde:

- δ_i : delta do neurónio j;
- e_i : erro no neurónio j;
- $\dot{\varphi}_j(v_j)$: derivada da função de ativação do neurónio j;
- $\sum_k \delta_k(n) w_{kj}$: somatório ponderado dos deltas calculados para os neurónios da camada posterior à qual o neurónio j está conectado.

Em síntese, o algoritmo segue dois passos principais. O primeiro passo é a propagação para a frente, durante a qual os pesos não são alterados e o sinal de erro é calculado ao fim da propagação. No segundo passo, os deltas derivados do sinal de erro são propagados para trás e os pesos são atualizados. Cada vez que esses dois passos são executados se dá uma sessão de treinamento, também chamada de época de treinamento. São executadas quantas épocas forem necessárias até que a rede tenha aprendido suficientemente de acordo com algum parâmetro chamado condição de parada.

4.2 Banco de Espectros

Os espectros de luz das SNs foram obtidos no repositório aberto The Open Supernova Catalog [14], atualmente mantido por dois pesquisadores do Harvard-Smithsonian Center for Astrophysics (CfA). O acervo é uma coletânea dos dados de 17 bases de espectros mais contribuições individuais. Nele, estão disponíveis espectros de SNs dos tipos Ia, Ib, Ic, II e os outros tipos que são classificados por fotometria. A Tabela 3 discrimina a quantidade total de dados que foram obtidos para utilização no classificador, porém nem todos os dados foram utilizados nos treinamentos e testes porque passaram por etapas de limpeza e pré-processamento de dados que desabilita a utilização de alguns deles. Essas etapas são exploradas nas próximas subsecções.

Quantidade de espectros	Quantidade de SNs
9405	3751
627	105
742	153
2128	874
12902	4883
	9405 627 742 2128

Tabela 3: Quantidade total de dados obtidos no The Open Supernova Catalog.

4.3 Pré-Processamento

Os espectros utilizados neste trabalho passaram por uma etapa de pré-processamento para que as informações extraídas fossem mais confiáveis. Após essa etapa, a quantidade de dados disponíveis para o desenvolvimento do classificador foi reduzida. Isso aconteceu porque foram descobertos alguns arquivos sem as informações de comprimento de onda e de fluxo de radiação necessárias para a caracterização do espectro.

4.3.1 Correção do Redshift

[13] explica que em 1929, Edwin P. Hubble observou um redshift (desvio para o vermelho) nos espectros de luz de galáxias distantes da Terra, que indicavam que elas estavam se afastando de nós a uma velocidade proporcional à sua distância. O desvio para o vermelho pode ser creditado principalmente à expansão do Universo. Portanto, a correção do redshift é necessária para que o espectro capturado seja analisado como se o evento correspondente estivesse em repouso. Dessa forma, as linhas espectrais podem ser comparadas com as linhas medidas em laboratório. A correção é feita com a Equação 4.

$$\lambda_0 = \frac{\lambda}{z+1} \tag{4}$$

Onde:

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

4.3.2 Dupla-Filtragem com Filtro Savitzky-Golay

O sistema de Dupla-Filtragem de dados espectrais foi proposto por [2], e é caracterizado por ser um sistema de ajuste de dados para eliminar ruídos e inconsistências em sinais. Este sistema foi testado particularmente em dados espectrais e apresenta bom desempenho no sentido de remoção de ruídos e preservação das características de sinais. A Figura 7 ilustra como estas inconsistências estão presentes nos sinais de SNs ao se realizar uma busca gradiente pelos picos e vales, no esquema de Dupla-Filtragem o objetivo é eliminar estas inconsistências e utilizar apenas os pontos mais importantes dos espectros, os picos e vales reais.

A Figura 7 revela uma busca por picos em vales em uma região (5500-7000 Å) do espectro original da SN1998dx. Esse trecho apresenta apenas um vale (linha de absorção) útil na análise de elementos, entretanto uma busca simples pelos picos e vales identificou uma grande quantidade de pontos. Esses pontos quando presentes em uma análise por RNAs, ou por outras técnicas de aprendizagem de máquina podem interferir severamente na análise identificando falsos positivos ou propagando o erro proveniente do ruído para as etapas finais da análise. No esquema de Dupla-Filtragem estas inconsistências são removidas e uma análise segura pode ser feita, pois todos os dados apresentam apenas os picos e vales reais dos espectros.

O sistema de Dupla-Filtragem consiste em 3 etapas diferentes denominadas: Normalização, Filtragem Simples e Filtragem Dupla.

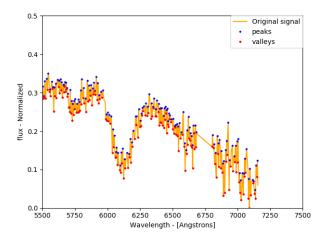


Figura 7: Busca gradiente de picos e vales em um espectro de SN.

- Normalização: Consiste em uma interpolação linear do sinal em 1000 pontos. Em seguida, é feita uma normalização nos valores de fluxo dos espectros para vector de magnitude 1, nesta etapa o sinal está normalizado e pode ser submetido a uma filtragem.
- Filtragem Simples: Consiste em aplicar o filtro de Savitzky-Golay com o tamanho da janela de 71 pontos e com polinómio de grau 9 nos dados normalizados. Esta etapa resulta em um dado suavizado pelo filtro, em que ruídos e resíduos não estão mais presentes. Entretanto, apenas uma filtragem simples não foi capaz de eliminar os ruídos dos espectros e desta forma é que se desenvolve a próxima etapa.
- Filtragem Dupla: Consiste em aplicar o filtro de Savitzky-Golay com o tamanho de janela de 71 pontos e com polinómio de grau 9. Neste ponto, foi possível identificar apenas os picos e vales reais do espectro removendo as inconsistências e ruídos do espectro. A Figura 8 ilustra o espectro normalizado que é utilizado para o treinamento da CIntIa 2.0.

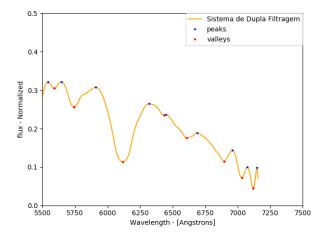


Figura 8: Espectro de uma SN resultante da Dupla-Filtragem.

A construção do sistema de Dupla-Filtragem ocorreu após a comparação com outras estratégias da

literatura ([1], [15], [26]), que não obtiveram desempenho suficiente para o tratamento destes dados. Os parâmetros escolhidos para a Dupla-Filtragem foram derivados de testes das abordagens citadas a fim de escolher um parâmetro de janela de pontos e de grau de polinómio que se aproximasse de uma resposta optimizada. A Figura 9 ilustra a comparação destes sistemas de filtragem com relação ao sistema de Dupla-Filtragem.

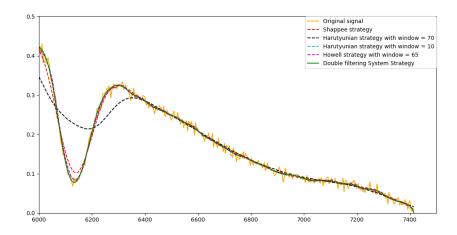


Figura 9: Comparação da Dupla-Filtragem com os sistemas de filtragem para espectros de SNs consultados na literatura.

4.3.3 Seleção de Intervalo de Comprimento de Onda

Como supracitado, a quantidade de espectros efetivamente utilizados é menor que o total apresentado na Tabela 3. Além dos arquivos sem informação, outra razão para o decremento no número de espectros, foi a seleção apenas dos que possuem intervalo de comprimento de onda entre 4000Å e 7000Å, podendo variar para mais e/ou para menos. A escolha desse intervalo decorre da observação das linhas espectrais importantes para a avaliação dos espectros, as quais estão dentro da faixa de luz visível. Anteriormente, a CIntIa 1.0 aceitava espectros com intervalos maiores (3800-7400 Å), com essa mudança conseguimos inserir mais espectros porque a exigência em relação ao tamanho do espectro é menor. A Figura 10 apresenta a quantidade de dados remanescente após a aplicação desse critério de seleção em comparação com a quantidade de dados usados nos treinamentos e teste da primeira versão da CIntIa.

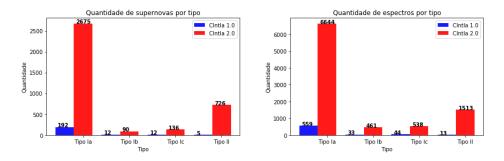


Figura 10: Quantidade de espectros de SNs utilizados no desenvolvimento da CIntIa 2.0 em comparação à quantidade de dados da CIntIa 1.0.

4.4 Extração de Características

Após o pré-processamento, as características necessárias para o treinamento das RNAs que compõem a CIntIa são extraídas. Primeiramente, cada espectro passa por uma interpolação a cada 8 pontos começando em 4000Å até 7000Å, resultando em 375 pontos. As entradas são os pontos contidos em intervalos definidos originalmente por [21], que se referem às regiões em que os elementos H, Si, S e He se manifestam e são as mesmas regiões analisadas por especialistas humanos. Os intervalos são os seguintes:

- 5000Å a 6500Å: para classificar em tipo Ia ou não;
- 5500Å a 7000Å: para classificar em tipo Ib ou não;
- 5500Å a 6500Å: para classificar em tipo Ic ou não;
- 4000Å a 5000Å e 6000Å a 7000Å: para classificar em tipo II ou não.

Cada espectro origina quatro conjuntos de entrada, um para cada RNA. A Figura 11 mostra uma representação gráfica desses intervalos. O primeiro intervalo (acima à esquerda) é a representação dos 188 pontos, na faixa de comprimento de onda 5000-6500 Å, que constituem a entrada da RNA que classifica entre espectros Ia e não-Ia. O segundo intervalo (acima à direita) é a representação dos 187 pontos, na faixa de comprimento de onda 5500-7000 Å, que constituem a entrada da RNA que classifica entre espectros Ib e não-Ib. O terceiro intervalo (abaixo à esquerda) é a representação dos 125 pontos, na faixa de comprimento de onda 5500-6500 Å, que constituem a entrada da RNA que classifica entre espectros Ic e não-Ic. E o quarto intervalo (abaixo à direita) é a representação dos 251 pontos, nas faixas de comprimento de onda 4000-5000 Å e 6000-7000Å, que constituem a entrada da RNA que classifica entre espectros II e não-II.

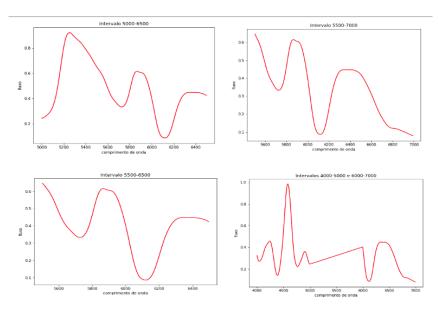


Figura 11: Intervalos escolhidos como entradas das 4 RNAs.

4.5 Parâmetros de Treinamento

Os parâmetros necessários para definir cada RNA da CIntIa são os mesmos apresentados por [21]:

- Taxa de aprendizado = 0.5;
- Momentum = 0.3;
- Bias = 1;

- Erro tolerado = 0.001;
- Função de ativação = Sigmoide.

Executou-se 7 experimentos na CIntIa para cada RNA, como mostrado na Tabela 4, a fim de escolher a topologia mais adequada para cada uma delas. O máximo de camadas ocultas permitidas pelo sistema são duas. A quantidade de espectros selecionados para o treinamento equivale a 60% do total, enquanto 20% é usado na validação e 20% no teste.

Id. da topologia	Neurónios na camada 1	Neurónios na camada 2
1	5	0
2	10	0
3	25	0
4	40	0
5	10	10
6	20	4
7	40	8

Tabela 4: Topologias testadas para escolha da mais adequada para cada RNA do sistema.

5 Resultados e Discussão

Os resultados alcançados neste trabalho redundam no aperfeiçoamento da primeira versão da CIntIa. As topologias das quatro RNAs que compõe o sistema foram ajustadas e uma arquitetura é proposta. Nesta secção tratamos dos resultados dos testes, a nova arquitetura da CIntIa e a discussão decorrente daí, seguida das comparações possíveis com os trabalhos relacionados tratados na revisão da literatura.

5.1 Resultados da Classificação: Tipo Ia

A Tabela 5 exibe a quantidade de espectros usados neste teste, por tipo. Percebemos que a quantidade de espectros do tipo Ia é bastante superior. Isso acontece porque a quantidade de dados do tipo Ia no banco de espectros também é muito maior do que os outros tipos. Optou-se por usar todos os espectros disponíveis, assim o classificador está mais preparado para a diversidade do mundo real, principalmente do tipo Ia. Os espectros do tipo Ia utilizados nesta classificação são aqueles auferidos nas fases espectrais \geq -10.9 e \leq +10.9, ou seja, entre -10 e +10 dias do brilho máximo. Os espectros dos outros tipos estão sem restrição no que concerne à fase espectral.

Tabela	a 5: (Quantida	ade de	e espectros	usado	s no	teste d	la c	classifica	acão	entre	Tipo	Ia e	Tipo	Não-Ia	ι.
		C								3		r-		r-		

Tipo	Quantidade de espectros
Ia	703
Ib	90
Ic	106
II	296

As Tabelas 6 e 7 mostram a matriz de confusão e as métricas escolhidas para avaliação dos classificadores binários, de acordo com [28]. Para avaliação dos resultados, também é usado o Índice Kappa que mede a concordância entre duas ou mais classificação [18].

Tabela 6: Matriz de confusão da classificação entre Tipo Ia e Tipo Não-Ia.

	Tipo Ia	Tipo Não-Ia
Tipo Ia	609	94
Tipo Não-Ia	6	486

Tabela 7: Métricas de avaliação da classificação entre Tipo Ia e Tipo Não-Ia.

Acurácia	0.92
Precisão	0.99
Recall	0.87
F1-Score	0.92
Especificidade	0.99
AUC	0.93
Índice Kappa	0.83

A matriz de confusão deixa claro que a maioria dos erros são falsos negativos, ou seja, o classificador não reconhece alguns espectros de SNs do tipo Ia. Essa característica se reflete na métrica Recall, que indica a eficácia para encontrar os positivos. Enquanto isso, a Especificidade, que indica a eficácia para encontrar os negativos é bastante alta. No entanto, o Índice Kappa atribuído é interpretado textualmente como Quase Perfeita (concordância da classificação feita pela CIntIa e a classificação dos especialistas humanos), a interpretação máxima dentre as possíveis, que são em ordem crescente: Pobre (<0.0); Fraca (>0.0 e <0.2); Razoável (>0.2 e <0.4); Moderada (>0.4 e <0.6); Substancial (>0.6 e <0.8); Quase Perfeita (>0.8).

5.2 Resultados da Classificação: Tipo Não-Ia

Nesta subsecção, agrupamos os resultados das 3 RNAs que classificam os espectros em Ib, Ic e II, ou seja, os Não-Ia. A Tabela 8 exibe a quantidade de espectros usados nos 3 testes, por tipo. Todos os espectros estão em fases espectrais diversas.

Tabela 8: Quantidade de espectros usados nos 3 testes de classificação Tipo Não-Ia.

	Espectros Ia	Espectros Ib	Espectros Ic	Espectros II
Classificação Ib	1294	89	106	295
Classificação Ic	1291	90	106	295
Classificação II	1293	90	106	297

As Tabelas 9, 10 e 11 mostram a matrizes de confusão de cada RNA, enquanto a Tabela 12 apresenta as métricas de avaliação.

Tabela 9: Matriz de confusão da classificação entre Tipo Ib e Tipo Não-Ib.

	Tipo Ib	Tipo Não-Ib
Tipo Ib	52	37
Tipo Não-Ib	8	1687

Tabela 10: Matriz de confusão da classificação entre Tipo Ic e Tipo Não-Ic.

	Tipo Ic	Tipo Não-Ic
Tipo Ic	20	86
Tipo Não-Ic	9	1667

Tabela 11: Matriz de confusão da classificação entre Tipo II e Tipo Não-II.

	Tipo II	Tipo Não-II
Tipo II	230	67
Tipo Não-II	8	1481

Tabela 12: Métricas de avaliação das 3 RNAS que classificam os tipos Não-Ia.

	Classificação Ib	Classificação Ic	Classificação II	
Acurácia	0.97	0.95	0.96	
Precisão	0.87	0.69	0.97	
Recall	0.58	0.19	0.77	
F1-Score	0.70	0.30	0.86	
Especificidade	0.99	0.99	0.99	
AUC	0.79	0.59	0.88	
Índice Kappa	0.69	0.28	0.84	

Nas 3 classificações, a maioria dos erros são falsos negativos. Os valores mais baixos de Recall, F1-Score (indica a qualidade do classificador) e AUC (capacidade do classificador de evitar classificações falsas) deixam claro essa deficiência. O Índice Kappa atribuído concede a qualidade Quase Perfeita ao classificador de tipo II, Substancial para o de tipo Ib e Razoável para o de tipo Ic.

A grande quantidade de falsos negativos, principalmente nas classificações de Ib e Ic podem ser explicadas pela formação comum dos dois tipos de SNs. SNs dos tipo Ib e Ic são ambas de colapso de núcleo o que as separa é apenas a presença do elemento He nas do tipo Ib que está ausente no tipo Ic, isso ocorre porque antes de explodir as estrelas que originam SNs tipo Ic expelem a camada de He, enquanto as estrelas que originam o tipo Ib explodem ainda com essa camada. Portanto, não há um padrão bem definido para os espectros de SNs dos tipos Ib e Ic, o que dificulta a sua classificação por métodos automáticos.

5.3 CIntIa 2.0

Os resultados dos testes realizados em cada uma das RNAs do sistema levaram ao desenvolvimento de uma arquitetura para a segunda versão da CIntIa, que está sendo proposta neste trabalho. Cada uma das RNAs é um módulo na visão geral do classificador, a Figura 12 mostra as topologias das RNAs em cada módulo. Enquanto a Figura 13 apresenta a visão geral da arquitetura da CIntIa 2.0.

O fluxo da classificação inicia identificando se o espectro, previamente pré-processado, é do tipo II ou não, assim a negativa pode ser interpretada como tipo I. Em seguida, são classificados os do tipo Ia. Na sequência os espectros devem ser classificados como tipo Ib ou tipo Ic, que é a diferenciação mais desafiadora a ser feita pelo sistema inteligente, assim como é para os especialistas humanos. Caso o espectro não seja classificado em nenhum dos módulos ele recebe o rótulo de tipo não identificado. A Tabela 13 mostra as métricas de avaliação da CIntIa 2.0 considerando o sistema como um classificador multi-classes, as métricas foram calculadas de acordo com [28].

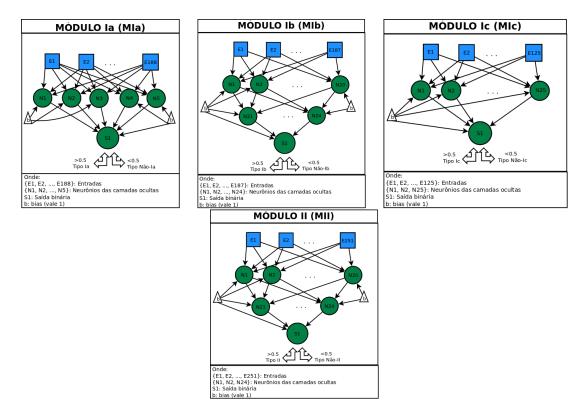


Figura 12: Módulos que compõem a CIntIa 2.0.

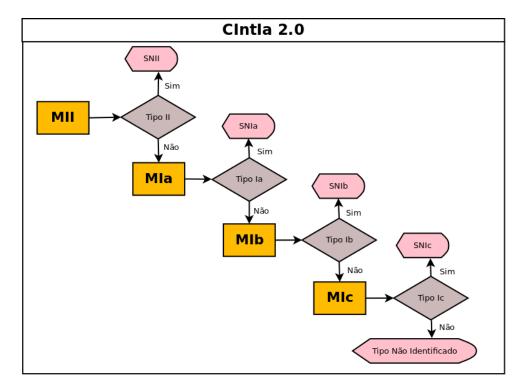


Figura 13: Arquitetura da CIntIa 2.0.

Menteas de avanação da					
Acurácia Média	0.95				
Taxa de Erro	0.05				
Precisão M	0.88				
$Precisão\mu$	0.97				
Recall M	0.60				
$\text{Recall}\mu$	0.76				
F1-Score M	0.71				
F1-Scoreu	0.85				

Tabela 13: Métricas de avaliação da CIntIa 2.0.

A acurácia média tem um excelente resultado, pois a acurácia dos módulos individuais também é muito boa. A taxa de erro é baixa, mas os erros que acontecem são maioritariamente de falsos negativos, logo isso se reflete nos valores de Recall. Apesar disso, o F1-Score (principalmente o μ) confere ao classificador um bom índice.

5.4 Comparação da CIntIa 2.0 com Revisão da Literatura

Uma comparação entre a CIntIa 2.0 e os outros classificadores consultados na literatura é importante para avaliar em que aspectos ela representa uma melhoria e depreender o quão vantajosa é a sua utilização. A Tabela 14 apresenta alguns critérios escolhidos para efetuar essa verificação.

Tabela 14: Comparação entre a CIntIa 2.0 e os classificadores descritos na Revisão da Literatura. Os valores NC indicam que a informação não consta no trabalho. Para as duas versão da CIntIa, as métricas Acurácia, Precisão, Recall e F1-Score se referem aos valores μ .

Classificador	[5]	[16]	[21]	[25]	[29]	[2]	CIntIa 2.0
Inteligência Artificial?	Não	Não	Sim	Sim	Não	Sim	Sim
Espectros Ia	879	1009	559	486	146	3082	6644
Espectros não-Ia	675	1699	90	NC	35	615	2512
Menor Fase Espectral	-15	-15	-3	-3	-5	-15	-1435
Maior Fase espectral	+70	+600	+7	+3	+5	+2959	+8303
Acurácia	NC	NC	0.98	NC	0.95	0.73	0.95
Precisão	NC	NC	0.97	NC	NC	0.93	0.97
Recall	NC	NC	0.94	NC	NC	0.72	0.76
F1-Score	NC	NC	0.95	NC	NC	0.83	0.85

Considerando a quantidade de dados e a abrangência das fases espectrais, a segunda versão da CIntIa é superior a todos os outros classificadores, ou seja, ela compreende uma diversidade maior de espectros. Apesar dos dados de teste não serem exactamente os mesmos testados nos outros classificadores, podemos dizer que a CIntIa 2.0 transcende todos os classificadores consultados, que apresentam bons resultados apenas para espectros na fase de brilho máximo. Considerando que a expectativa de tornar o sistema um classificador atuante em conjunto com telescópios, essa é uma característica importante, ou seja, a CIntIa 2.0 tem grande capacidade de generalização pois o seu treino foi realizado com uma gama de padrões bem maior do que os classificadores comparados. A sua acurácia média e a precisão μ são equiparáveis aos sistemas que também apresentam essa informação. Em relação à CIntIa 1.0, o sistema que adaptamos promovendo melhorias, a CIntIa 2.0 alcança a interpretação "Quase Perfeita"do Índice Kappa, a mesma de sua predecessora. Além disso, a quantidade de dados melhora a análise realizada anteriormente, evidenciando a capacidade das RNAs em aprender padrões dos tipos Ia e II e a dificuldade em diferenciar espectros de SNs Ib e Ic as quais têm a mesma origem física.

6 Conclusão

O trabalho descrito neste artigo, apresenta a CIntIa 2.0, a segunda versão do Classificador Inteligente de Supernovas do tipo Ia, cuja primeira versão foi proposta em 2016. A CIntIa 1.0 foi treinada com uma quantidade limitada de dados, provenientes de apenas uma base de espectros dentre as disponíveis online. A atualização desse sistema é uma necessidade atual, pois cada vez mais cresce a quantidade de telescópios varrendo os céus em busca de SNs. Nesse contexto, a CIntIa 2.0 apresenta melhorias adequadas ao classificador original. Aumentou-se a quantidade e variedade de dados, a amplitude das fases espectrais considerada foi alargada e os resultados, consequentemente, são bons. A CintIa 2.0 faz distinção, com excelência, entre espectros de SNs do tipo II e os outros, do tipo I. As SNs do tipo Ia, as mais utilizadas nas pesquisas de Cosmologia, também são adequadamente reconhecidas pelo classificador. A classificação do tipo Ib tem bons resultados, mas não excelentes, enquanto a classificação do tipo Ic é apenas regular. Uma comparação com outros sistemas relatados na literatura atestam a qualidade da CIntIa 2.0. Uma arquitetura que conecta as RNAs individuais (módulos) em um sistema completo ainda não havia sido proposta para a primeira versão e é um avanço na garantia de que a classificação não será ambígua. Todos os espectros recebem apenas um rótulo identificando o tipo da SN a qual pertencem, ao fim da execução do sistema.

Futuramente, espera-se definir as topologias e outros parâmetros de cada módulo da CIntIa automaticamente, assim é possível melhorar a qualidade da classificação, já que mais testes serão feitos em um tempo menor. Outro desdobramento almejado deste trabalho é avançar na classificação de SNs, propondo formas inteligentes de concluir em que fase espectral a SN está. Torna-se, assim, menos custoso, em termos temporais, descobrir se a SN está na fase de brilho máximo no momento da obtenção do espectro, informação de grande relevância para os estudos que usam SNIa como vela-padrão.

Agradecimentos

Agradecemos à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) pelo suporte financeiro, Código de Financiamento 001. Agradecemos ao Instituto Nacional de Pesquisas Espaciais (INPE) e ao Instituto de Estudos Avançados (IEAv) por disponibilizar espaço físico e recursos computacionais.

Referências

- [1] D Andrew Howell, Peter Hoeflich, Lifan Wang, and J Craig Wheeler. Evidence for asphericity in a subluminous type ia supernova: Spectropolarimetry of sn 1999by. *The Astrophysical Journal*, 556, 01 2001. DOI: https://doi.org/10.1086/321584.
- [2] L. R. Arantes Filho. Classificação inteligente de supernovas utilizando sistemas de regras nebulosas. Dissertação (mestrado em computação aplicada), Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2018.
- [3] S. Blondin, K. S. Mandel, and R. P. Kirshner. Do spectra improve distance measurements of type ia supernovae? *Astronomy & Astrophysics*, 526(A81), February 2011. DOI: https://doi.org/10.1051/0004-6361/201015792.
- [4] S. Blondin, T. Matheson, R. P. Kirshner, K. S. Mandel, P. Berlind, M. Calkins, P. Challis, P. M. Garnavich, S. W. Jha, M. Modjaz, A. G. Riess, and B. P. Schmidt. The spectroscopic diversity of type ia supernovae. *The Astronomical Journal*, 143(5):126, 2012.
- [5] Stéphane Blondin and John L. Tonry. Determining the type, redshift, and age of a supernova spectrum. *The Astrophysical Journal*, 666(2), 2007.
- [6] B. W. Carroll and D. A. Ostlie. *An Introduction to Modern Astrophysics*. Pearson Addison-Wesley, San Francisco, 2007. 1358 p.
- [7] A. Damineli and J. Steiner. Fascínio do Universo. Odysseus Editora, São Paulo, 2010. 120 p.

- [8] Departamento de Física da Southern Methodist University,?
- [9] Departamento de Física e Astronomia da Georgia State University, 1998.
- [10] E. Ferneda. Redes neurais e sua aplicação em sistemas de recuperação de informação. Ci. Inf. Brasilia, 35(1):25-30, 2006. DOI: http://dx.doi.org/10.1590/S0100-19652006000100003.
- [11] Alexei V. Filippenko. Optical spectra of supernovae. *Annual Review of Astronomy and Astrophysics*, 35(1):309-355, 1997. DOI: https://dx.doi.org/10.1146/annurev.astro.35.1.309.
- [12] D. V. Fiorin, F. R. Martins, N. J. Schuch, and E. B. Pereira. Aplicações de redes neurais e previsões de disponibilidade de recursos energéticos solares. *Revista Brasileira de Ensino de Física*, 33:01 20, 2011. DOI: http://dx.doi.org/10.1590/S1806-11172011000100009.
- [13] Juan Garcia-Bellido. Astrophysics and cosmology. In *High-energy physics. Proceedings, European School, ESHEP'99, Casta-Papiernicka, Slovak Republic, August 22-September 4, 1999*, pages 109–186, 1999.
- [14] J. Gillochon, J. Parrent, L. Z. Kelley, and R. Margutti. An open catalog for supernova data. *The Astrophysical Journal*, 835(1):64, 2017. DOI: http://dx.doi.org/10.3847/1538-4357/835/1/64.
- [15] A H. Harutyunyan, Patrick Pfahler, Andrea Pastorello, S Taubenberger, M Turatto, E Cappellaro, S Benetti, Nancy Elias-Rosa, H Navasardyan, Stefano Valenti, Vallery Stanishev, F Patat, Marco Riello, Giuliano Pignata, and W Hillebrandt. Esc supernova spectroscopy of non-esc targets. Astronomy and Astrophysics, 488, 09 2008. DOI: https://doi.org/10.1051/0004-6361:20078859.
- [16] Avet Harutyunyan. Automatic Objective Classification of Supernovae. PhD thesis, Universitá degli Studi de Padova, 2008.
- [17] S. Haykin. Redes neurais: princípios e práticas. Bookman, Porto Alegre, 2001.
- [18] J. R. Landis and G. G. Koch. The measurement of observer agreement for categorical data. *Biometrics*, 33(1):159–174, 1977. DOI: https://doi.org/10.2307/2529310.
- [19] G. F. Luger. Inteligência Artificial. Pearson Education do Brasil, São Paulo, 2013.
- [20] M. Modjaz, S. Blondin, R. P. Kirshner, T. Matheson, P. Berlind, F. B. Bianco, M. L. Calkins, P. Challis, P. Garnavich, M. Hicken, S. Jha, Y. Q. Liu, and G. H. Marion. Optical spectra of 73 stripped-envelope core-collapse supernovae. *The Astronomical Journal*, 147(5), 2014.
- [21] Marcelo Módolo. Classificação Automática de Supernovas Usando Redes Neurais Artificiais. PhD thesis, Instituto Nacional de Pesquisas Espaciais, 2016.
- [22] K. S. Oliveira Filho and M. F. O. Saraiva. *Astronomia e Astrofísica*. UFRGS, Rio Grande do Sul, 2014. 784 p.
- [23] S. Perlmutter, G. Aldering, G. Goldhaber, R. A. Knop, P. Nugent, P. G. Castro, S. Deustua, S. Fabbro, A. Goobar, D. E. Groom, I. M. Hook, A. G. Kim, M. Y. Kim, J. C. Lee, N. J. Nunes, R. Pain, C. R. Pennypacker, R. Quimby, C. Lidman, R. S. Ellis, M. Irwin, R. G. McMahon, P. Ruiz-Lapuente, N. Walton, B. Schaefer, B. J. Boyle, A. V. Filippenko, T. Matheson, A. S. Fruchter, N. Panagia, H. J. M. Newberg, W. J. Couch, and The Supernova Cosmology Project. Measurements of omega and lambda from 42 high-redshift supernovae. The Astrophysical Journal, 517(2):565, 1999. DOI: https://doi.org/10.1086/307221.
- [24] Adam G. Riess, Alexei V. Filippenko, Peter Challis, Alejandro Clocchiatti, Alan Diercks, Peter M. Garnavich, Ron L. Gilliland, Craig J. Hogan, Saurabh Jha, Robert P. Kirshner, B. Leibundgut, M. M. Phillips, David Reiss, Brian P. Schmidt, Robert A. Schommer, R. Chris Smith, J. Spyromilio, Christopher Stubbs, Nicholas B. Suntzeff, and John Tonry. Observational evidence from supernovae for an accelerating universe and a cosmological constant. The Astronomical Journal, 116(3):1009, 1998.

- [25] M. Sasdelli, E. E. O. Ishida, R. Vilalta, M. Aguena, V. C. Busti, H. Camacho, A. M. M. Trindade, F. Gieseke, R. S. de Souza, Y. T. Fantaye, and P. A. Mazzali. Exploring the spectroscopic diversity of type ia supernovae with dracula: a machine learning approach. *Monthly Notices of the Royal Astronomical Society*, 461(2):2044–2059, 2016. DOI: https://doi.org/10.1093/mnras/stw1228.
- [26] Stanek K. Z. Pogge R. W. Garnavich P. M. Shappee, B. J. No stripped hydrogen in the nebular spectra of nearby type ia supernova 2011fe. *The Astrophysical Journal Letters*, 762(1):L5, 2012. DOI: https://doi.org/10.1088/2041-8205/762/1/15.
- [27] J. M. Silverman, J. J. Kong, and A. V. Filippenko. Berkeley supernova ia program ii. initial analysis of spectra obtained near maximum brightness. *Monthly Notices of the Royal Astronomical Society*, 425(3):1819–1888, 2012. DOI: https://doi.org/10.1111/j.1365-2966.2012.21269.x.
- [28] M. Sokolova and G. Lapalme. A systematic analysis of performance measures for classification tasks. *Information Processing and Management*, 45:427-437, 2009. DOI: https://doi.org/10.1016/j.ipm.2009.03.002.
- [29] Fengwu Sun and Avishay Gal-Yam. Quantitative classification of type i supernovae using spectroscopic features at maximum brightness. ArXiv e-prints, 2017.
- [30] M. Turatto. Classification of Supernovae, pages 21–36. Springer Berlin Heidelberg, Berlin, Heidelberg, 2003. DOI: https://doi.org/10.1007/3-540-45863-8_3.
- [31] Massimo Turatto, Stefano Benetti, and Andrea Pastorello. Supernova classes and subclasses. AIP Conference Proceedings, 937(1):187–197, 2007. DOI: https://doi.org/10.1063/1.3682902.
- [32] X. Wang, A. V. Filippenko, M. Ganeshalingam, W. Li, J. M. Silverman, L. Wang, R. Chornock, R. J. Foley, E. L. Gates, B. Macomber, F. J. D. Serduke, T. N. Steele, and D. S. Wong. Improved distances to type ia supernovae with two spectroscopic subclasses. *The Astrophysical Journal Letters*, 699(2):L139, 2009. DOI: https://doi.org/10.1088/0004-637X/699/2/L139.
- [33] S. E. Woosley and Thomas A. Weaver. The physics of supernova explosions. *Annual Review of Astronomy and Astrophysics*, 24(1):205-253, 1986. DOI: https://doi.org/10.1146/annurev.aa. 24.090186.001225.
- [34] Y. Zhu, L. Wang, Y. Xiangyan, B. Gu, X. Li, S. Yang, X. Gong, F. Du, Y. Qi, and L. Xu. Kunlun dark universe survey telescope. volume 9145, page 9145, 2014. DOI: https://doi.org/10.1117/12.2055768.