

UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL  
CÂMPUS DE CHAPADÃO DO SUL  
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA

ROSILENE ESTEVÃO

**DISCRIMINAÇÃO DE ESPÉCIES DE EUCALIPTO UTILIZANDO  
APRENDIZAGEM DE MÁQUINA E VARIÁVEIS HIPERESPECTRAIS**

CHAPADÃO DO SUL – MS

2023

UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL  
CÂMPUS DE CHAPADÃO DO SUL  
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA

ROSILENE ESTEVÃO

**DISCRIMINAÇÃO DE ESPÉCIES DE EUCALIPTO UTILIZANDO  
APRENDIZAGEM DE MÁQUINA E VARIÁVEIS HIPERESPECTRAIS**

Orientadora: Prof.<sup>a</sup>. Dr.<sup>a</sup> Larissa Pereira Ribeiro Teodoro

Dissertação apresentada à Universidade Federal de Mato Grosso do Sul, como requisito para obtenção do título de Mestre em Agronomia, área de concentração: Produção Vegetal.

CHAPADÃO DO SUL – MS

2023



## PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONOMIA

### CERTIFICADO DE APROVAÇÃO

**DISCENTE:** Rosilene Estevão

**ORIENTADOR:** Dra. Larissa Pereira Ribeiro Teodoro

**TÍTULO:** Discriminação de espécies de eucalipto utilizando aprendizagem de máquina e variáveis hiperespectrais

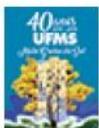
**AVALIADORES:**

Profa. Dra. Larissa Pereira Ribeiro Teodoro

Prof. Dr. Paulo Eduardo Teodoro

Profa. Dra. Glauce Tais de Oliveira Sousa Azevedo

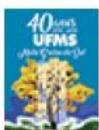
Chapadão do Sul, 08 de março de 2023.



Documento assinado eletronicamente por **Paulo Eduardo Teodoro**, Professor do Magisterio Superior, em 08/03/2023, às 08:40, conforme horário oficial de Mato Grosso do Sul, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Glauce Tais de Oliveira Sousa Azevedo**, Professora do Magistério Superior, em 08/03/2023, às 10:10, conforme horário oficial de Mato Grosso do Sul, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Larissa Pereira Ribeiro**, Professora do Magistério Superior, em 08/03/2023, às 15:38, conforme horário oficial de Mato Grosso do Sul, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

## **AGRADECIMENTOS**

Com gratidão, agradeço primeiramente a Deus - fonte de toda sabedoria e poder, pela conclusão deste trabalho.

A minha Orientadora, Profa. Dra. Larissa Pereira Ribeiro Teodoro, pela oportunidade de trabalharmos juntas, pelos ensinamentos, por seu exemplo profissional de dedicação à pesquisa, ensino e, sobretudo, pela disponibilidade e paciência em todos os momentos.

Aos docentes do Programa de Pós-Graduação em Agronomia, pelo apoio e pela disponibilidade que sempre demonstraram durante o curso.

Aos membros da banca examinadora, Prof. Dr. Paulo Eduardo Teodoro e Profa. Dra. Glauce Tais de Oliveira Sousa Azevedo pela disponibilidade e contribuição na melhoria do trabalho.

À Universidade Federal de Mato Grosso do Sul (UFMS) e ao Programa de Pós-Graduação em Agronomia pela oportunidade e estrutura, por ter me acolhido como aluna de mestrado e por todo o aprendizado que me proporcionou.

## LISTA DE FIGURAS

- Figura 1.** Reflectâncias espectrais das cinco espécies de eucalipto avaliadas por sensor hiperespectral.....13
- Figura 2.** Gráfico de barras para as variáveis classificação correta (%) para discriminação de cinco espécies de eucalipto usando modelos de aprendizado de máquina (AM) e diferentes tamanhos dos conjuntos de dados (200 amostras de cada espécie, 100 amostras de cada espécie e 50 amostras de cada espécie. Letras maiúsculas comparam o tamanho da amostra, enquanto letras minúsculas comparam as diferentes técnicas de AM pelo teste de Scott-Knott a 5% de probabilidade.....14

**RESUMO:** A identificação de espécies arbóreas é muito importante para o manejo e monitoramento dos recursos florestais. A identificação de espécies com base em bandas espectrais obtidas através de um sensor hiperespectral, combinados com técnicas de aprendizagem de máquina (AM) pode contribuir para a construção de tecnologias que possibilitem a realização de inventários florestais precisos, reduzindo mão de obra e tempo. Neste estudo, foi investigada a eficácia da classificação de espécies florestais usando imagens hiperespectrais de cinco espécies de eucalipto (*Eucalyptus camaldulensis*, *Corymbia citriodora*, *E. saligna*, *E. grandis* e *E. urophylla*). Primeiro, foram realizadas leituras espectrais coletadas das 200 folhas de cada espécie e dividido em três conjuntos de dados: um conjunto contendo 50 amostras por espécie, um segundo conjunto com 100 amostras por espécie, e um terceiro conjunto com 200 amostras por espécie. Os modelos de AM testados foram: Regressão logística (RL), redes neurais artificiais Perceptron Multicamadas (RNA), árvore de decisão (algoritmos J48 e REPTree) e floresta aleatória (RF). As classificações das espécies florestais foram realizadas pelos cinco modelos de AM em uma validação cruzada estratificada aleatória. Após a obtenção da porcentagem de classificação correta e F-measure as médias foram agrupadas pelo teste Scott-Knott a 5% de probabilidade. O modelo de AM mais preciso na identificação de espécies de eucalipto foi a RNA. Não houve diferença estatística na porcentagem de classificação correta entre os três tamanhos dos conjuntos de dados. Portanto, 50 folhas são suficientes para diferenciar as espécies de eucalipto avaliadas.

**Palavras-chave:** Inteligência computacional. Bandas espectrais. Estudos Florestais. Sensoriamento hiperespectral.

**ABSTRACT:** The identification of tree species is very important for the management and monitoring of forest resources. The identification of species based on spectral bands obtained through a hyperspectral sensor, combined with machine learning (ML) techniques can contribute to the construction of technologies that allow the realization of accurate forest inventories, reducing labor and time. In this study, we investigated the effectiveness of forest species classification using hyperspectral images of five eucalyptus species (*Eucalyptus camaldulensis*, *Corymbia citriodora*, *E. saligna*, *E. grandis* and *E. urophylla*). First, spectral readings were collected from 200 leaves of each species and divided into three data sets: one set containing 50 samples per species, a second set with 100 samples per species, and a third set with 200 samples per species. The ML models tested were: Logistic regression (RL), Multilayer Perceptron artificial neural networks (ANN), decision tree (J48 and REPTree algorithms) and random forest (RF). The classifications of forest species were carried out by the five AM models in a random stratified cross-validation. After obtaining the percentage of correct classification and F-measure, the averages were grouped by the Scott-Knott test at 5% probability. The most accurate ML model for identifying eucalyptus species was the ANN. There was no statistical difference in the percentage of correct classification between the three dataset sizes. Therefore, 50 leaves are enough to differentiate the evaluated eucalyptus species.

**Keywords:** Computational intelligence. Spectral bands. Forest Studies. Hyperspectral sensing.

## SUMÁRIO

<b>1. INTRODUÇÃO.....</b>	<b>9</b>
<b>2. MATERIAL E MÉTODOS.....</b>	<b>11</b>
<b>2.1. Condução do experimento.....</b>	<b>11</b>
<b>2.2. Aquisição dos dados espectrais.....</b>	<b>11</b>
<b>2.3. Tamanho da amostra e modelos de aprendizagem de máquina.....</b>	<b>12</b>
<b>2.4. Análises estatísticas.....</b>	<b>12</b>
<b>3. RESULTADOS E DISCUSSÃO.....</b>	<b>13</b>
<b>3.1. Assinatura espectral das espécies de eucalipto.....</b>	<b>13</b>
<b>3.2. Aprendizagem de máquina e tamanho do conjunto de dados na discriminação de espécies.....</b>	<b>14</b>
<b>4. CONCLUSÕES.....</b>	<b>16</b>
<b>REFERÊNCIAS.....</b>	<b>16</b>
<b>MATERIAL SUPLEMENTAR.....</b>	<b>19</b>

## 1. INTRODUÇÃO

O Brasil é um país que se destaca no setor florestal. O total da área destinada a árvores plantadas no país chegou a 9,93 milhões de hectares e a produtividade do eucalipto atingiu seu maior nível desde 2014, chegando a 38,9 m<sup>3</sup>/ha/ano em 2021 (IBÁ, 2022). No país existem cerca de 7.880 espécies arbóreas (SNIF, 2020). Mais de 4 mil delas estão presentes no Catálogo de Árvores do Brasil, elaborado pelo Laboratório de Produtos Florestais do Serviço Florestal Brasileiro. Este catálogo contém cerca de 15 mil nomes comuns e comerciais relacionados aos nomes científicos das respectivas espécies.

Na perspectiva de estudo de uma grande área de floresta, o uso do sensoriamento remoto permite análises temporais e espaciais das feições da superfície terrestre e o estudo da dinâmica das áreas florestais (CARVALHO JÚNIOR et al., 2006). Treitz e Howarth (1999) destacam que o uso do sensoriamento remoto e suas tecnologias para fins de análise de aspectos físicos, estruturais e mapeamentos são muito utilizados em estudos florestais. Além disso, o sensoriamento remoto disponibiliza dados que podem ser amplamente aplicados para os estudos fenológicos, o monitoramento de ocorrências de desmatamento e previsão de safras agrícolas (PONZONI; SHIMABUKURO, 2010).

A rápida evolução tecnológica de sensores remotos vem proporcionando a obtenção de dados digitais com uma resolução espacial cada vez maior, o que faz com que cada vez mais se opte pelo uso de técnicas de sensoriamento remoto para a realização de estudos florestais (SOUZA et al., 2007). Franklin (2001) destaca que o sensoriamento remoto tanto no aspecto de obtenção de dados, quanto na técnica de análise das condições de florestas possui uma grande aplicabilidade para o estudo florestal, uma vez que ele permite avaliar em diversas escalas os problemas referentes ao manejo de florestas.

No sensoriamento remoto, as características dos alvos estão fortemente ligadas a sua interação com o espectro eletromagnético. Deste modo, as folhas são os órgãos mais importantes para a caracterização espectral da vegetação, por refletirem as condições da planta e por conterem substâncias que caracterizam o comportamento espectral como a clorofila, principal substância indicadora das condições fenológicas da vegetação (PONZONI et al., 2012). Nesse contexto, Ponzoni et al. (2012) afirmam que o comportamento espectral da vegetação no espectro eletromagnético, compreendida entre a região do visível e do infravermelho, resulta em uma curva de reflectância característica. Estas curvas de reflectância emitidas pelo dossel das plantas podem ser utilizadas na discriminação de espécies florestais, o

que é especialmente útil no manejo de plantios florestais, programas de melhoramento genético, inventários florestais e mapeamento de áreas de vegetação nativa.

Devido à importância da discriminação de espécies, especialmente em grandes áreas florestais, diversos métodos de classificação tem sido desenvolvidos nas últimas duas décadas, sobretudo para o processamento de dados obtidos por sensores multi e hiperespectrais (CHEN et al., 2015). Segundo Mochida et al. (2019), os algoritmos de aprendizagem de máquina (AM) aceleram e automatizam a análise de imagens melhorando o processamento de dados do sensor. Isso porque o uso de AM possibilita o desenvolvimento de algoritmos para serem utilizados em grandes conjuntos de dados e com informações complexas (como dados de imagens espectrais) que requerem integração entre eles (SANTANA et al., 2023, GAVA et al., 2022).

A rede neural artificial (RNA) é um método que a partir de conjunto de dados de entrada e saída podem ser treinadas para análises correspondentes de acordo com Pazoki e Pazoki (2011). Diversas interpretações complexas são possíveis com as RNAs, como previsões físicas, químicas, segurança alimentar e agricultura de precisão (GOYAL, 2014). O Random Forest (RF) é um algoritmo de AM utilizado para uma combinação de preditores de árvores, de modo que cada árvore depende dos valores de um vetor aleatório amostrado independentemente e com a mesma distribuição para todas as árvores da floresta (BREIMAN, 2001).

Estudos mostram que os algoritmos RNA e RF usados para processar dados espectrais também podem ser utilizados com o objetivo de estimar diâmetro à altura do peito e altura total de eucaliptos, tornando-se uma abordagem promissora para contribuir para o inventário e manejo de florestas plantadas (DA SILVA et al., 2021, BORGES et al., 2022). Como no estudo proposto por de Oliveira et al. (2021), onde foi observado que algoritmos RF aplicados a dados espectrais também são uma abordagem apropriada para reconhecer diferentes espécies de eucalipto em relação ao seu crescimento.

Diante disso, o uso correto dessas informações apresenta uma série de vantagens, que pode possibilitar a identificação e mapeamento de diferentes espécies florestais a partir do uso de variáveis hiperespectrais e modelos de aprendizagem de máquina, tornando-se uma ferramenta rápida e precisa para os mais diversos tipos de estudos relacionados com áreas florestais. Neste sentido, o objetivo desse estudo foi verificar a acurácia de discriminação de diferentes espécies de eucalipto utilizando aprendizagem de máquina e variáveis hiperespectrais.

## 2. MATERIAL E MÉTODOS

### 2.1. Condução do experimento

O experimento foi conduzido no período de outubro de 2022 a janeiro de 2023 na área experimental da Universidade Federal de Mato Grosso do Sul, localizada no município de Chapadão do Sul (18°41'33''S, 52°40'45''W, com 810 m de altitude). Segundo a classificação de Köppen, o clima da região é tropical úmido (Aw) com estação chuvosa de outubro a abril e estação seca entre maio e setembro. A precipitação média varia de 750 a 1.800 mm ano<sup>-1</sup> e a temperatura média anual varia de 20 a 25°C (PEEL et al., 2007). O solo da área é classificado como Latossolo Vermelho de textura média, com as seguintes propriedades químicas na camada de 0-20 cm: pH (CaCl<sub>2</sub>): 4,9; matéria orgânica: 31,5 g dm<sup>-3</sup>; fósforo: 13,6 mg dm<sup>-3</sup>; hidrogênio + alumínio (H + Al): 5,4; potássio: 0,29 cmolc dm<sup>-3</sup>; cálcio: 2,8 cmolc dm<sup>-3</sup>; magnésio: 0,5 cmolc dm<sup>-3</sup>; capacidade de troca catiônica (CTC): 9,0 cmolc dm<sup>-3</sup>; saturação por base: 39,9 %. Coroamento, capina, controle de formigas e aplicação de herbicidas (glifosato) foram realizados quando necessário.

A área experimental consiste em um plantio de diferentes espécies de eucalipto com 10 anos de implantação. O delineamento experimental utilizado na área é o de blocos ao acaso com quatro repetições, com 28 plantas dentro de cada parcela experimental. Os tratamentos foram compostos por cinco espécies de eucalipto (*E. camaldulensis*, *C. citriodora*, *E. saligna*, *E. grandis* e *E. urophylla*). As coletas de folhas para leituras espectrais foram realizadas em agosto de 2022. Foram coletadas aleatoriamente 50 folhas de cada espécie em cada unidade experimental, totalizando 200 amostras. As amostras foram acondicionadas em sacos plásticos e levadas para laboratório para subsequente análise hiperespectral, que foi realizada em até 12 horas após as coletas.

### 2.2. Aquisição dos dados espectrais

As leituras foram realizadas com um sensor hiperespectral de baixo custo, da empresa Ocean Insight<sup>®</sup>, modelo STS-VIS (Ocean Insight, USA). A faixa de reflectância compreendeu as bandas espectrais de 335,14 a 820,80 nm, com 0,45 mm de comprimento cada, totalizando 1024 bandas espectrais, que foram nomeadas de B (B1, B2, B3,..., B1024) e foram utilizadas como variáveis de entrada nos cinco modelos de aprendizagem de máquina para a classificação das diferentes espécies de eucalipto. A descrição da faixa espectral referente a cada uma das variáveis de entrada (B1 a B1024) estão descritas na Tabela S1 (Material Suplementar).

### **2.3. Tamanho da amostra e modelos de aprendizagem de máquina**

Foram avaliados três conjuntos de dados com diferentes tamanhos de amostras: um conjunto contendo 50 amostras por espécie, um segundo conjunto com 100 amostras por espécie, e um terceiro conjunto com 200 amostras por espécie. As 1024 bandas obtidas pelo sensor hiperespectral foram utilizadas como variáveis de entrada nos cinco modelos de classificação, enquanto que as cinco espécies de eucalipto avaliadas foram utilizadas como variáveis de saída.

Os modelos de AM testados para a classificação das diferentes espécies de eucalipto foram Regressão logística (RL), redes neurais artificiais Perceptron Multicamadas (RNA), árvore de decisão (algoritmos J48 e REPTree) e floresta aleatória (RF). A técnica convencional de regressão logística (RL) foi utilizada como modelo controle. A RNA testada consiste em um modelo Perceptron Multicamadas com duas camadas ocultas contendo dez neurônios cada (EGMONT-PETERSEN; DE RIDDER; HANDELS, 2002). O modelo J48 é uma adaptação do classificador C4.5 que pode ser usado em problemas de classificação com uma etapa de poda adicional baseada em uma estratégia de redução de erro (SNOUSY et al., 2011). O REPTree utiliza a lógica da árvore de decisão e cria várias árvores em diferentes interações. Em seguida, seleciona a melhor árvore utilizando o ganho de informação e realiza a poda de redução do erro como critério de divisão (KALMEGH, 2015). O modelo RF é capaz de produzir várias árvores de predição para o mesmo conjunto de dados e usar um esquema de votação entre todas essas árvores aprendidas para prever novos valores (BELGIU; DRĂGU, 2016).

A classificação das espécies de eucalipto foi realizada pelos cinco modelos em uma validação cruzada estratificada aleatória com k-fold=10 e dez repetições (100 execuções para cada modelo). Os parâmetros obtidos para avaliação do desempenho dos modelos e entradas foram a porcentagem de classificações corretas (CC, %) e a medida-F (F-measure). Todas as análises de AM foram realizadas com software o Weka 3.9.4. utilizando a configuração padrão para todos os modelos testados (BOUCKAERT et al., 2010) em uma CPU Intel® Core™ i7 com 16 Gb de RAM.

### **2.4. Análises estatísticas**

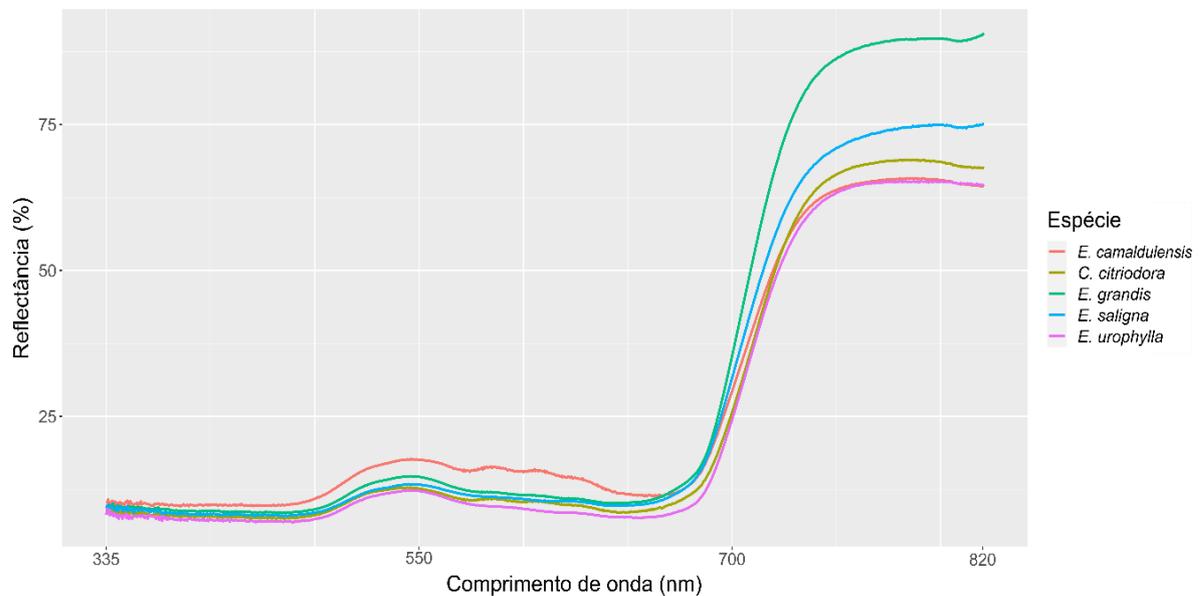
Após a obtenção das estatísticas CC e F-measure, foi realizada análise de variância considerando um delineamento inteiramente casualizado com 10 repetições (folds). As médias de CC e F-measure considerando os diferentes tamanhos de amostra e técnicas de AM foram agrupadas pelo teste de Scott-Knott a 5% de probabilidade. Para expressar graficamente estes resultados, foram construídos gráficos de barras para cada parâmetro (CC e F-measure). Todas

as análises estatísticas foram realizadas no software R (R CORE TEAM, 2018) com auxílio dos pacotes ExpDes.pt e ggplot2.

### 3. RESULTADOS E DISCUSSÃO

#### 3.1. Assinatura espectral das espécies de eucalipto

O resultado das curvas espectrais extraídas do sensor hiperespectral para as 200 repetições de cada espécie está representado na Figura 1.



**Figura 1.** Reflectâncias espectrais das cinco espécies de eucalipto avaliadas por sensor hiperespectral.

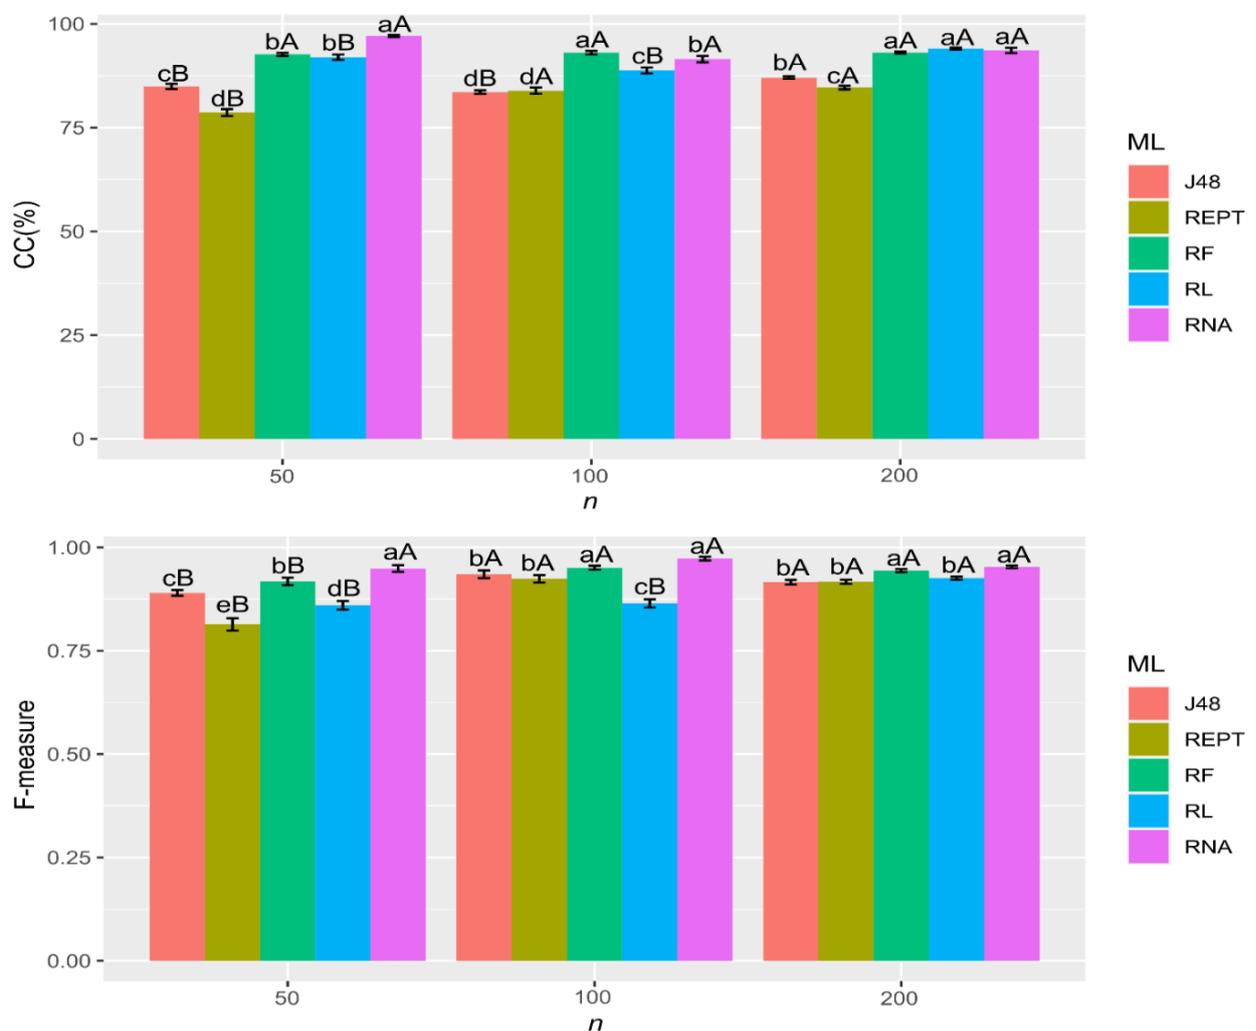
Foram selecionados, para esse estudo, os valores correspondentes à faixa do visível, compreendidos no intervalo espectral de 400 a 700 nm e do infravermelho próximo, compreendidos no intervalo espectral entre 701 a 820 nm. De acordo com Watslawick e Kirchner (2004), em cada faixa do espectro eletromagnético, a radiação eletromagnética interage com a vegetação de forma diferenciada. Neste estudo observa-se que as diferenças entre as assinaturas espectrais analisadas das espécies *E. camaldulensis* e *E. urophylla* foram pouco significativas na região do espectro visível nos comprimentos de onda entre 400 a 700 nm, correspondente à característica de absorção de radiação eletromagnética pela clorofila (DELLA-SILVA et al., 2022).

Por outro lado, entre as espécies *C. citriodora*, *E. grandis* e *E. saligna* a diferenciação ocorreu de forma mais intensa na região do espectro infravermelho próximo a partir da faixa espectral de 701 nm, região que está relacionada ao espalhamento de luz no mesófilo e interage

com a estrutura interna da folha (SANCHEZ-AZOFEIFA et al., 2009). Com base nas curvas espectrais obtidas, os dados de reflectância hiperespectral forneceram características espectrais inequívocas para distinguir as cinco espécies de eucalipto.

### 3.2. Aprendizagem de máquina e tamanho do conjunto de dados na discriminação de espécies.

A acurácia de classificação das cinco espécies de eucalipto considerando os diferentes modelos de AM e tamanho do conjunto de dados é expresso graficamente na Figura 2. Os resultados indicam uma discriminação acurada, com resultados superiores a 75% e 0,75 para CC e F-measure, respectivamente.



**Figura 2.** Gráfico de barras para as variáveis classificação correta (%) para discriminação de cinco espécies de eucalipto usando modelos de aprendizado de máquina (AM) e diferentes tamanhos dos conjuntos de dados (200 amostras de cada espécie, 100 amostras de cada espécie e 50 amostras de cada

espécie). Letras maiúsculas comparam o tamanho da amostra, enquanto letras minúsculas comparam as diferentes técnicas de AM pelo teste de Scott-Knott a 5% de probabilidade.

Na perspectiva da classificação, foram utilizados cinco métodos de AM para a discriminação das espécies de eucalipto e os experimentos de classificação também foram conduzidos com relação aos impactos dos tamanhos de amostras.

Usando as mesmas entradas, a RL e o RF obtiveram o mesmo desempenho estatístico que a RNA, onde forneceram resultados de classificação superiores a 80%. Porém pode ser visto que as RNAs possuem o melhor desempenho de porcentagem de classificação correta (%) e F-measure nos três tamanhos de amostras, enquanto os algoritmos RF e RL obtiveram a melhor acurácia de porcentagem de classificação correta (%) somente no conjunto de 100 amostras e 200 amostras, respectivamente. As árvores de decisão REPTree e J48 tiveram as menores acurácias entre todos os tamanhos de amostras testados.

Os modelos de RNAs têm demonstrado resultados superiores para classificações supervisionadas (GAVA et al., 2022), são comumente utilizados em sensoriamento remoto devido sua facilidade de aprender os padrões das classes (BARROS et al., 2020). Trabalho como o de Gava et al. (2022) corrobora os resultados encontrados, ao avaliarem qual técnica de AM é mais acurada na identificação de cultivares de soja usando apenas bandas espectrais. Neste estudo, foram comparados os resultados de classificação correta (%) e coeficiente Kappa entre modelos de classificações por redes neurais artificiais (RNA), rede de função de base radial (RFB), algoritmos de árvore de decisão J48 e árvore de poda de erro reduzido (REPTree), floresta aleatória (RF) e máquina de vetores de suporte (SVM). Estes autores encontraram que a RNA foi a técnica mais precisa na identificação de cultivares de soja, com 92,18% para classificação correta e 0,91 para coeficiente Kappa.

Santana et al. (2023), em seu estudo de classificação de genótipos de soja para características industriais usando variáveis espectrais como entradas em modelos de AM, ao comparar as métricas estatísticas de classificação correta (%) e F-score, também encontraram que os algoritmos de classificação que alcançaram as maiores acurácias foram as redes neurais artificiais (RNA), árvore de decisão (REPTree) e máquina de vetores de suporte (SVM).

Ao analisar o desdobramento dos modelos dentro das entradas apresentadas na Figura 2, pode-se constatar que a RNA se destacou por atingir as maiores médias de classificação correta e F-measure independentemente do tamanho da amostra utilizada. Essas descobertas demonstram que é possível distinguir espécies de eucalipto utilizando uma quantidade menor de amostras de variáveis hiperespectrais como entrada nos modelos de aprendizagem de

máquina. Isso representa um importante avanço científico para o mapeamento de áreas florestais no mundo, pois fornecem informações sobre plantios florestais com economia de tempo e mão de obra.

#### 4. CONCLUSÕES

É possível discriminar espécies de eucalipto com precisão usando bandas espectrais como entrada nos modelos de aprendizagem de máquina testados. No geral, todos os algoritmos de AM tiveram alta acurácia de classificação (superior a 75% CC e 0,75 F-measure), mas a RNA se destacou pela eficiência em classificar acuradamente as espécies de eucalipto com o menor número de amostras (50 folhas por espécies).

Ao avaliar o tamanho das amostras dentro de cada modelo, o uso do conjunto de 50 amostras por espécie se tornou mais viável, reduzindo mão-de-obra e tempo nas coletas e avaliações de amostras. Tais resultados representam um importante avanço científico para programas de melhoramento e inventários florestais, demonstrando ser possível a discriminação de espécies de eucalipto utilizando variáveis hiperespectrais e aprendizagem de máquina de forma rápida, acurada e em larga escala.

#### REFERÊNCIAS

- BARROS, G.V. P. et al. Eficiência de Redes Neurais Artificiais na Classificação de Uso e do Solo da Bacia Hidrográfica do Rio Japarutuba-SE. **Revista Brasileira de Meteorologia**, v. 35, p. 823-833, 2020.
- BELGIU, M.; DRĂGU, L. Random forest in remote sensing: A review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 114, p. 24–31, 2016.
- BORGES, M.V.V. et al. High-throughput phenotyping of two plant-size traits of *Eucalyptus* species using neural networks. **Journal of Forestry Research**, v. 33, p. 591–599, 2022. <https://doi.org/10.1007/s11676-021-01360-6>
- BOUCKAERT R, FRANK E, HALL M, KIRKBY R, REUTEMANN P, SEEWALD A, 2010. WEKA manual for version 3-7-1, 2010.
- BREIMAN, L. Random Forests. **Kluwer Academic Publishers**. Manufactured in The Netherlands, Machine Learning, 45, 5–32, 2001.

CARVALHO JÚNIOR, O. A. et al. Identificação regional da Floresta Estacional Decidual na bacia do Rio Paraná a partir da análise multitemporal de imagens MODIS. **Revista Brasileira de Geofísica**, v.24, n.3, São Paulo. 2006.

CHEN, Y; ZHAO, X; JIA, X. Spectral–Spatial Classification of Hyperspectral Data Based on Deep Belief Network. **IEEE JOURNAL OF SELECTED TOPICS IN APPLIED EARTH OBSERVATIONS AND REMOTE SENSING**, v. 8, n. 6, p. 2381-2392, 2015.

DA SILVA, A.K.V. et al. Predicting Eucalyptus Diameter at Breast Height and Total Height with UAV-Based Spectral Indices and Machine Learning. **Forest**, v.12, 582, 2021. <https://doi.org/10.3390/f12050582>

DE OLIVEIRA, B.R. et al. Eucalyptus growth recognition using machine learning methods and spectral variables. **Forest Ecology and Management**, v. 497, 119496, 2021. <https://doi.org/10.1016/j.foreco.2021.119496>.

DELLA-SILVA, J.L. et al. Amazonian species evaluation using leaf-based spectroscopy data and dimensionality reduction approaches. **Remote Sensing Applications: Society and Environment**, v. 26, 100742, 2022. <https://doi.org/10.1016/j.rsase.2022.100742>.

EGMONT-PETERSEN, M.; DE RIDDER, D.; HANDELS, H. Image processing with neural networks- A review. **Pattern Recognition**, v. 35, n. 10, p. 2279–2301, 2002.

FRANKLIN, S. E. Remote sensing for sustainable forest management. New York: **CRC Press**, 2001. 407 p.

GAVA, R. et al. Soybean Cultivars Identification Using Remotely Sensed Image and Machine Learning Models. **Sustainability**, v.14, 7125, 2022. <https://doi.org/10.3390/su14127125>

GOYAL, S. Artificial Neural Networks in Fruits: A Comprehensive Review. **International Journal of Image, Graphics and Signal Processing**. v. 6. p. 53-63, 2014.

INDÚSTRIA BRASILEIRA DE ÁRVORES (IBÁ). **Relatório anual**. 2022. <https://iba.org/datafiles/publicacoes/relatorios/relatorio-anual-iba2022-compactado.pdf>

KALMEGH, S. Analysis of WEKA Data Mining Algorithm REPTree, Simple Cart and RandomTree for Classification of Indian News. **International Journal of Innovative Science, Engineering & Technology**, v. 2, n. 2, p. 438–446, 2015.

MOCHIDA, K. et al. Computer vision-based phenotyping for improvement of plant productivity: a machine learning perspective, **GigaScience**, n.1, 2019, giy153. <https://doi.org/10.1093/gigascience/giy153>

PAZOKI, A.; PAZOKI, Z.; Classification system for rain fed wheat grain cultivars using artificial neural network. **African Journal of Biotechnology**. v. 10, 2011.

PEEL, M. C., Finlayson, B. L., and McMahon, T. A. Updated world map of the Köppen-Geiger climate classification, *Hydrol. Earth Syst. Sci.*, v.11, p.1633–1644, 2007.

PONZONI, F. J.; SHIMABUKURO, Y. E. Sensoriamento remoto no estudo da vegetação. São José dos Campos: **Parêntese**, 2010, 127p.

PONZONI, F. J. et al. Sensoriamento Remoto da Vegetação. São José dos Campos, SP, **Oficina de Textos**, 2ª edição, 176 p., 2012.

R CORE TEAM. R: A language and environment for statistical computing. **R Foundation for Statistical Computing**, Vienna, Austria, 2018. URL <https://www.R-project.org/>.

SÁNCHEZ-AZOFEIFA, G. A, et al. Differences in leaf traits, leaf internal structure, and spectral reflectance between two communities of lianas and trees: Implications for remote sensing in tropical environments. **Remote Sensing of Environment**, v. 113, p.2076–2088, 2009. <https://doi.org/10.1016/j.rse.2009.05.013>.

SANTANA, D. C et al. Classification of soybean genotypes for industrial traits using UAV multispectral imagery and machine learning. **Remote Sensing Applications: Society and Environment**, v. 29, 100919, 2023. <https://doi.org/10.1016/j.rsase.2023.100919>.

SISTEMA NACIONAL DE INFORMAÇÕES FLORESTAIS (SNIF). **Espécies Florestais**. 2020. <https://snif.florestal.gov.br/pt-br/especies-florestais>.

SOUZA, C. C et al. Técnicas de sensoriamento remoto como subsídios aos estudos de florestas implantadas no Brasil – uma revisão bibliográfica. **Ciência Florestal**, Santa Maria, v. 17, n. 4, p. 409-417, 2007.

SNOUSY, M. B. et al. Suite of decision tree-based classification algorithms on cancer gene expression data. **Egyptian Informatics Journal**, v. 12, n. 2, p. 73–82, 2011. <http://dx.doi.org/10.1016/j.eij.2011.04.003>.

TREITZ, P. M.; HOWARTH, P. J. Hyperspectral remote sensing for estimating biophysical parameters of forest ecosystems. **Progress in Physical Geography**, v. 23, p. 359-390, 1999.

WATSLAWICK, L. F.; KIRCHNER, F. F. Estimativas de biomassa e carbono utilizando imagens de satélite de alta resolução. In: **fixação de carbono: atualizações, projetos e pesquisas**, 2004, Curitiba. Anais... Curitiba, 2004. p. 133-151.

## MATERIAL SUPLEMENTAR

Tabela S1. Bandas espectrais avaliadas e seus respectivos comprimentos de onda (CO, nm).

<b>Banda</b>	<b>CO (nm)</b>						
<b>B1</b>	335.14	<b>B257</b>	452.72	<b>B513</b>	572.94	<b>B769</b>	695.80
<b>B2</b>	335.59	<b>B258</b>	453.19	<b>B514</b>	573.42	<b>B770</b>	696.29
<b>B3</b>	336.04	<b>B259</b>	453.65	<b>B515</b>	573.89	<b>B771</b>	696.77
<b>B4</b>	336.50	<b>B260</b>	454.11	<b>B516</b>	574.37	<b>B772</b>	697.26
<b>B5</b>	336.95	<b>B261</b>	454.58	<b>B517</b>	574.84	<b>B773</b>	697.74
<b>B6</b>	337.41	<b>B262</b>	455.04	<b>B518</b>	575.32	<b>B774</b>	698.23
<b>B7</b>	337.86	<b>B263</b>	455.51	<b>B519</b>	575.79	<b>B775</b>	698.71
<b>B8</b>	338.32	<b>B264</b>	455.97	<b>B520</b>	576.27	<b>B776</b>	699.20
<b>B9</b>	338.77	<b>B265</b>	456.44	<b>B521</b>	576.74	<b>B777</b>	699.68
<b>B10</b>	339.22	<b>B266</b>	456.90	<b>B522</b>	577.22	<b>B778</b>	700.17
<b>B11</b>	339.68	<b>B267</b>	457.37	<b>B523</b>	577.69	<b>B779</b>	700.65
<b>B12</b>	340.13	<b>B268</b>	457.83	<b>B524</b>	578.17	<b>B780</b>	701.14
<b>B13</b>	340.59	<b>B269</b>	458.30	<b>B525</b>	578.64	<b>B781</b>	701.62
<b>B14</b>	341.04	<b>B270</b>	458.76	<b>B526</b>	579.12	<b>B782</b>	702.11
<b>B15</b>	341.50	<b>B271</b>	459.23	<b>B527</b>	579.59	<b>B783</b>	702.59
<b>B16</b>	341.95	<b>B272</b>	459.69	<b>B528</b>	580.07	<b>B784</b>	703.08
<b>B17</b>	342.41	<b>B273</b>	460.16	<b>B529</b>	580.54	<b>B785</b>	703.57
<b>B18</b>	342.86	<b>B274</b>	460.62	<b>B530</b>	581.02	<b>B786</b>	704.05
<b>B19</b>	343.32	<b>B275</b>	461.09	<b>B531</b>	581.50	<b>B787</b>	704.54
<b>B20</b>	343.77	<b>B276</b>	461.55	<b>B532</b>	581.97	<b>B788</b>	705.02
<b>B21</b>	344.23	<b>B277</b>	462.02	<b>B533</b>	582.45	<b>B789</b>	705.51
<b>B22</b>	344.68	<b>B278</b>	462.48	<b>B534</b>	582.92	<b>B790</b>	706.00
<b>B23</b>	345.14	<b>B279</b>	462.95	<b>B535</b>	583.40	<b>B791</b>	706.48
<b>B24</b>	345.59	<b>B280</b>	463.41	<b>B536</b>	583.87	<b>B792</b>	706.97
<b>B25</b>	346.05	<b>B281</b>	463.88	<b>B537</b>	584.35	<b>B793</b>	707.45
<b>B26</b>	346.50	<b>B282</b>	464.35	<b>B538</b>	584.82	<b>B794</b>	707.94
<b>B27</b>	346.96	<b>B283</b>	464.81	<b>B539</b>	585.30	<b>B795</b>	708.43
<b>B28</b>	347.41	<b>B284</b>	465.28	<b>B540</b>	585.78	<b>B796</b>	708.91
<b>B29</b>	347.87	<b>B285</b>	465.74	<b>B541</b>	586.25	<b>B797</b>	709.40
<b>B30</b>	348.32	<b>B286</b>	466.21	<b>B542</b>	586.73	<b>B798</b>	709.88
<b>B31</b>	348.78	<b>B287</b>	466.67	<b>B543</b>	587.20	<b>B799</b>	710.37
<b>B32</b>	349.23	<b>B288</b>	467.14	<b>B544</b>	587.68	<b>B800</b>	710.86
<b>B33</b>	349.69	<b>B289</b>	467.60	<b>B545</b>	588.16	<b>B801</b>	711.34
<b>B34</b>	350.15	<b>B290</b>	468.07	<b>B546</b>	588.63	<b>B802</b>	711.83
<b>B35</b>	350.60	<b>B291</b>	468.54	<b>B547</b>	589.11	<b>B803</b>	712.32
<b>B36</b>	351.06	<b>B292</b>	469.00	<b>B548</b>	589.58	<b>B804</b>	712.80
<b>B37</b>	351.51	<b>B293</b>	469.47	<b>B549</b>	590.06	<b>B805</b>	713.29
<b>B38</b>	351.97	<b>B294</b>	469.93	<b>B550</b>	590.54	<b>B806</b>	713.77
<b>B39</b>	352.42	<b>B295</b>	470.40	<b>B551</b>	591.01	<b>B807</b>	714.26
<b>B40</b>	352.88	<b>B296</b>	470.87	<b>B552</b>	591.49	<b>B808</b>	714.75
<b>B41</b>	353.33	<b>B297</b>	471.33	<b>B553</b>	591.97	<b>B809</b>	715.23

<b>B42</b>	353.79	<b>B298</b>	471.80	<b>B554</b>	592.44	<b>B810</b>	715.72
<b>B43</b>	354.25	<b>B299</b>	472.26	<b>B555</b>	592.92	<b>B811</b>	716.21
<b>B44</b>	354.70	<b>B300</b>	472.73	<b>B556</b>	593.39	<b>B812</b>	716.69
<b>B45</b>	355.16	<b>B301</b>	473.20	<b>B557</b>	593.87	<b>B813</b>	717.18
<b>B46</b>	355.61	<b>B302</b>	473.66	<b>B558</b>	594.35	<b>B814</b>	717.67
<b>B47</b>	356.07	<b>B303</b>	474.13	<b>B559</b>	594.82	<b>B815</b>	718.16
<b>B48</b>	356.53	<b>B304</b>	474.60	<b>B560</b>	595.30	<b>B816</b>	718.64
<b>B49</b>	356.98	<b>B305</b>	475.06	<b>B561</b>	595.78	<b>B817</b>	719.13
<b>B50</b>	357.44	<b>B306</b>	475.53	<b>B562</b>	596.25	<b>B818</b>	719.62
<b>B51</b>	357.89	<b>B307</b>	476.00	<b>B563</b>	596.73	<b>B819</b>	720.10
<b>B52</b>	358.35	<b>B308</b>	476.46	<b>B564</b>	597.21	<b>B820</b>	720.59
<b>B53</b>	358.81	<b>B309</b>	476.93	<b>B565</b>	597.68	<b>B821</b>	721.08
<b>B54</b>	359.26	<b>B310</b>	477.39	<b>B566</b>	598.16	<b>B822</b>	721.56
<b>B55</b>	359.72	<b>B311</b>	477.86	<b>B567</b>	598.64	<b>B823</b>	722.05
<b>B56</b>	360.18	<b>B312</b>	478.33	<b>B568</b>	599.12	<b>B824</b>	722.54
<b>B57</b>	360.63	<b>B313</b>	478.79	<b>B569</b>	599.59	<b>B825</b>	723.03
<b>B58</b>	361.09	<b>B314</b>	479.26	<b>B570</b>	600.07	<b>B826</b>	723.51
<b>B59</b>	361.55	<b>B315</b>	479.73	<b>B571</b>	600.55	<b>B827</b>	724.00
<b>B60</b>	362.00	<b>B316</b>	480.19	<b>B572</b>	601.02	<b>B828</b>	724.49
<b>B61</b>	362.46	<b>B317</b>	480.66	<b>B573</b>	601.50	<b>B829</b>	724.98
<b>B62</b>	362.91	<b>B318</b>	481.13	<b>B574</b>	601.98	<b>B830</b>	725.46
<b>B63</b>	363.37	<b>B319</b>	481.60	<b>B575</b>	602.46	<b>B831</b>	725.95
<b>B64</b>	363.83	<b>B320</b>	482.06	<b>B576</b>	602.93	<b>B832</b>	726.44
<b>B65</b>	364.28	<b>B321</b>	482.53	<b>B577</b>	603.41	<b>B833</b>	726.93
<b>B66</b>	364.74	<b>B322</b>	483.00	<b>B578</b>	603.89	<b>B834</b>	727.41
<b>B67</b>	365.20	<b>B323</b>	483.46	<b>B579</b>	604.36	<b>B835</b>	727.90
<b>B68</b>	365.66	<b>B324</b>	483.93	<b>B580</b>	604.84	<b>B836</b>	728.39
<b>B69</b>	366.11	<b>B325</b>	484.40	<b>B581</b>	605.32	<b>B837</b>	728.88
<b>B70</b>	366.57	<b>B326</b>	484.87	<b>B582</b>	605.80	<b>B838</b>	729.36
<b>B71</b>	367.03	<b>B327</b>	485.33	<b>B583</b>	606.27	<b>B839</b>	729.85
<b>B72</b>	367.48	<b>B328</b>	485.80	<b>B584</b>	606.75	<b>B840</b>	730.34
<b>B73</b>	367.94	<b>B329</b>	486.27	<b>B585</b>	607.23	<b>B841</b>	730.83
<b>B74</b>	368.40	<b>B330</b>	486.73	<b>B586</b>	607.71	<b>B842</b>	731.32
<b>B75</b>	368.85	<b>B331</b>	487.20	<b>B587</b>	608.19	<b>B843</b>	731.80
<b>B76</b>	369.31	<b>B332</b>	487.67	<b>B588</b>	608.66	<b>B844</b>	732.29
<b>B77</b>	369.77	<b>B333</b>	488.14	<b>B589</b>	609.14	<b>B845</b>	732.78
<b>B78</b>	370.23	<b>B334</b>	488.60	<b>B590</b>	609.62	<b>B846</b>	733.27
<b>B79</b>	370.68	<b>B335</b>	489.07	<b>B591</b>	610.10	<b>B847</b>	733.76
<b>B80</b>	371.14	<b>B336</b>	489.54	<b>B592</b>	610.57	<b>B848</b>	734.25
<b>B81</b>	371.60	<b>B337</b>	490.01	<b>B593</b>	611.05	<b>B849</b>	734.73
<b>B82</b>	372.06	<b>B338</b>	490.48	<b>B594</b>	611.53	<b>B850</b>	735.22
<b>B83</b>	372.51	<b>B339</b>	490.94	<b>B595</b>	612.01	<b>B851</b>	735.71
<b>B84</b>	372.97	<b>B340</b>	491.41	<b>B596</b>	612.49	<b>B852</b>	736.20
<b>B85</b>	373.43	<b>B341</b>	491.88	<b>B597</b>	612.96	<b>B853</b>	736.69
<b>B86</b>	373.89	<b>B342</b>	492.35	<b>B598</b>	613.44	<b>B854</b>	737.18
<b>B87</b>	374.34	<b>B343</b>	492.81	<b>B599</b>	613.92	<b>B855</b>	737.66

<b>B88</b>	374.80	<b>B344</b>	493.28	<b>B600</b>	614.40	<b>B856</b>	738.15
<b>B89</b>	375.26	<b>B345</b>	493.75	<b>B601</b>	614.88	<b>B857</b>	738.64
<b>B90</b>	375.72	<b>B346</b>	494.22	<b>B602</b>	615.36	<b>B858</b>	739.13
<b>B91</b>	376.17	<b>B347</b>	494.69	<b>B603</b>	615.83	<b>B859</b>	739.62
<b>B92</b>	376.63	<b>B348</b>	495.15	<b>B604</b>	616.31	<b>B860</b>	740.11
<b>B93</b>	377.09	<b>B349</b>	495.62	<b>B605</b>	616.79	<b>B861</b>	740.60
<b>B94</b>	377.55	<b>B350</b>	496.09	<b>B606</b>	617.27	<b>B862</b>	741.08
<b>B95</b>	378.01	<b>B351</b>	496.56	<b>B607</b>	617.75	<b>B863</b>	741.57
<b>B96</b>	378.46	<b>B352</b>	497.03	<b>B608</b>	618.23	<b>B864</b>	742.06
<b>B97</b>	378.92	<b>B353</b>	497.50	<b>B609</b>	618.71	<b>B865</b>	742.55
<b>B98</b>	379.38	<b>B354</b>	497.96	<b>B610</b>	619.18	<b>B866</b>	743.04
<b>B99</b>	379.84	<b>B355</b>	498.43	<b>B611</b>	619.66	<b>B867</b>	743.53
<b>B100</b>	380.30	<b>B356</b>	498.90	<b>B612</b>	620.14	<b>B868</b>	744.02
<b>B101</b>	380.75	<b>B357</b>	499.37	<b>B613</b>	620.62	<b>B869</b>	744.51
<b>B102</b>	381.21	<b>B358</b>	499.84	<b>B614</b>	621.10	<b>B870</b>	745.00
<b>B103</b>	381.67	<b>B359</b>	500.31	<b>B615</b>	621.58	<b>B871</b>	745.49
<b>B104</b>	382.13	<b>B360</b>	500.77	<b>B616</b>	622.06	<b>B872</b>	745.97
<b>B105</b>	382.59	<b>B361</b>	501.24	<b>B617</b>	622.54	<b>B873</b>	746.46
<b>B106</b>	383.05	<b>B362</b>	501.71	<b>B618</b>	623.01	<b>B874</b>	746.95
<b>B107</b>	383.50	<b>B363</b>	502.18	<b>B619</b>	623.49	<b>B875</b>	747.44
<b>B108</b>	383.96	<b>B364</b>	502.65	<b>B620</b>	623.97	<b>B876</b>	747.93
<b>B109</b>	384.42	<b>B365</b>	503.12	<b>B621</b>	624.45	<b>B877</b>	748.42
<b>B110</b>	384.88	<b>B366</b>	503.59	<b>B622</b>	624.93	<b>B878</b>	748.91
<b>B111</b>	385.34	<b>B367</b>	504.06	<b>B623</b>	625.41	<b>B879</b>	749.40
<b>B112</b>	385.80	<b>B368</b>	504.52	<b>B624</b>	625.89	<b>B880</b>	749.89
<b>B113</b>	386.26	<b>B369</b>	504.99	<b>B625</b>	626.37	<b>B881</b>	750.38
<b>B114</b>	386.71	<b>B370</b>	505.46	<b>B626</b>	626.85	<b>B882</b>	750.87
<b>B115</b>	387.17	<b>B371</b>	505.93	<b>B627</b>	627.33	<b>B883</b>	751.36
<b>B116</b>	387.63	<b>B372</b>	506.40	<b>B628</b>	627.81	<b>B884</b>	751.85
<b>B117</b>	388.09	<b>B373</b>	506.87	<b>B629</b>	628.29	<b>B885</b>	752.34
<b>B118</b>	388.55	<b>B374</b>	507.34	<b>B630</b>	628.77	<b>B886</b>	752.83
<b>B119</b>	389.01	<b>B375</b>	507.81	<b>B631</b>	629.24	<b>B887</b>	753.32
<b>B120</b>	389.47	<b>B376</b>	508.28	<b>B632</b>	629.72	<b>B888</b>	753.81
<b>B121</b>	389.93	<b>B377</b>	508.75	<b>B633</b>	630.20	<b>B889</b>	754.30
<b>B122</b>	390.38	<b>B378</b>	509.22	<b>B634</b>	630.68	<b>B890</b>	754.79
<b>B123</b>	390.84	<b>B379</b>	509.69	<b>B635</b>	631.16	<b>B891</b>	755.28
<b>B124</b>	391.30	<b>B380</b>	510.16	<b>B636</b>	631.64	<b>B892</b>	755.77
<b>B125</b>	391.76	<b>B381</b>	510.62	<b>B637</b>	632.12	<b>B893</b>	756.26
<b>B126</b>	392.22	<b>B382</b>	511.09	<b>B638</b>	632.60	<b>B894</b>	756.75
<b>B127</b>	392.68	<b>B383</b>	511.56	<b>B639</b>	633.08	<b>B895</b>	757.24
<b>B128</b>	393.14	<b>B384</b>	512.03	<b>B640</b>	633.56	<b>B896</b>	757.73
<b>B129</b>	393.60	<b>B385</b>	512.50	<b>B641</b>	634.04	<b>B897</b>	758.22
<b>B130</b>	394.06	<b>B386</b>	512.97	<b>B642</b>	634.52	<b>B898</b>	758.71
<b>B131</b>	394.52	<b>B387</b>	513.44	<b>B643</b>	635.00	<b>B899</b>	759.20
<b>B132</b>	394.98	<b>B388</b>	513.91	<b>B644</b>	635.48	<b>B900</b>	759.69
<b>B133</b>	395.44	<b>B389</b>	514.38	<b>B645</b>	635.96	<b>B901</b>	760.18

<b>B134</b>	395.90	<b>B390</b>	514.85	<b>B646</b>	636.44	<b>B902</b>	760.67
<b>B135</b>	396.36	<b>B391</b>	515.32	<b>B647</b>	636.92	<b>B903</b>	761.16
<b>B136</b>	396.82	<b>B392</b>	515.79	<b>B648</b>	637.40	<b>B904</b>	761.65
<b>B137</b>	397.27	<b>B393</b>	516.26	<b>B649</b>	637.88	<b>B905</b>	762.14
<b>B138</b>	397.73	<b>B394</b>	516.73	<b>B650</b>	638.36	<b>B906</b>	762.63
<b>B139</b>	398.19	<b>B395</b>	517.20	<b>B651</b>	638.84	<b>B907</b>	763.12
<b>B140</b>	398.65	<b>B396</b>	517.67	<b>B652</b>	639.32	<b>B908</b>	763.61
<b>B141</b>	399.11	<b>B397</b>	518.14	<b>B653</b>	639.80	<b>B909</b>	764.10
<b>B142</b>	399.57	<b>B398</b>	518.61	<b>B654</b>	640.28	<b>B910</b>	764.59
<b>B143</b>	400.03	<b>B399</b>	519.08	<b>B655</b>	640.76	<b>B911</b>	765.08
<b>B144</b>	400.49	<b>B400</b>	519.55	<b>B656</b>	641.25	<b>B912</b>	765.57
<b>B145</b>	400.95	<b>B401</b>	520.02	<b>B657</b>	641.73	<b>B913</b>	766.07
<b>B146</b>	401.41	<b>B402</b>	520.49	<b>B658</b>	642.21	<b>B914</b>	766.56
<b>B147</b>	401.87	<b>B403</b>	520.96	<b>B659</b>	642.69	<b>B915</b>	767.05
<b>B148</b>	402.33	<b>B404</b>	521.43	<b>B660</b>	643.17	<b>B916</b>	767.54
<b>B149</b>	402.79	<b>B405</b>	521.90	<b>B661</b>	643.65	<b>B917</b>	768.03
<b>B150</b>	403.25	<b>B406</b>	522.37	<b>B662</b>	644.13	<b>B918</b>	768.52
<b>B151</b>	403.71	<b>B407</b>	522.84	<b>B663</b>	644.61	<b>B919</b>	769.01
<b>B152</b>	404.17	<b>B408</b>	523.31	<b>B664</b>	645.09	<b>B920</b>	769.50
<b>B153</b>	404.63	<b>B409</b>	523.78	<b>B665</b>	645.57	<b>B921</b>	769.99
<b>B154</b>	405.09	<b>B410</b>	524.26	<b>B666</b>	646.05	<b>B922</b>	770.48
<b>B155</b>	405.55	<b>B411</b>	524.73	<b>B667</b>	646.53	<b>B923</b>	770.98
<b>B156</b>	406.02	<b>B412</b>	525.20	<b>B668</b>	647.01	<b>B924</b>	771.47
<b>B157</b>	406.48	<b>B413</b>	525.67	<b>B669</b>	647.50	<b>B925</b>	771.96
<b>B158</b>	406.94	<b>B414</b>	526.14	<b>B670</b>	647.98	<b>B926</b>	772.45
<b>B159</b>	407.40	<b>B415</b>	526.61	<b>B671</b>	648.46	<b>B927</b>	772.94
<b>B160</b>	407.86	<b>B416</b>	527.08	<b>B672</b>	648.94	<b>B928</b>	773.43
<b>B161</b>	408.32	<b>B417</b>	527.55	<b>B673</b>	649.42	<b>B929</b>	773.92
<b>B162</b>	408.78	<b>B418</b>	528.02	<b>B674</b>	649.90	<b>B930</b>	774.42
<b>B163</b>	409.24	<b>B419</b>	528.49	<b>B675</b>	650.38	<b>B931</b>	774.91
<b>B164</b>	409.70	<b>B420</b>	528.96	<b>B676</b>	650.86	<b>B932</b>	775.40
<b>B165</b>	410.16	<b>B421</b>	529.43	<b>B677</b>	651.34	<b>B933</b>	775.89
<b>B166</b>	410.62	<b>B422</b>	529.91	<b>B678</b>	651.83	<b>B934</b>	776.38
<b>B167</b>	411.08	<b>B423</b>	530.38	<b>B679</b>	652.31	<b>B935</b>	776.87
<b>B168</b>	411.54	<b>B424</b>	530.85	<b>B680</b>	652.79	<b>B936</b>	777.37
<b>B169</b>	412.00	<b>B425</b>	531.32	<b>B681</b>	653.27	<b>B937</b>	777.86
<b>B170</b>	412.46	<b>B426</b>	531.79	<b>B682</b>	653.75	<b>B938</b>	778.35
<b>B171</b>	412.93	<b>B427</b>	532.26	<b>B683</b>	654.23	<b>B939</b>	778.84
<b>B172</b>	413.39	<b>B428</b>	532.73	<b>B684</b>	654.72	<b>B940</b>	779.33
<b>B173</b>	413.85	<b>B429</b>	533.20	<b>B685</b>	655.20	<b>B941</b>	779.83
<b>B174</b>	414.31	<b>B430</b>	533.68	<b>B686</b>	655.68	<b>B942</b>	780.32
<b>B175</b>	414.77	<b>B431</b>	534.15	<b>B687</b>	656.16	<b>B943</b>	780.81
<b>B176</b>	415.23	<b>B432</b>	534.62	<b>B688</b>	656.64	<b>B944</b>	781.30
<b>B177</b>	415.69	<b>B433</b>	535.09	<b>B689</b>	657.12	<b>B945</b>	781.79
<b>B178</b>	416.15	<b>B434</b>	535.56	<b>B690</b>	657.61	<b>B946</b>	782.29
<b>B179</b>	416.62	<b>B435</b>	536.03	<b>B691</b>	658.09	<b>B947</b>	782.78

<b>B180</b>	417.08	<b>B436</b>	536.51	<b>B692</b>	658.57	<b>B948</b>	783.27
<b>B181</b>	417.54	<b>B437</b>	536.98	<b>B693</b>	659.05	<b>B949</b>	783.76
<b>B182</b>	418.00	<b>B438</b>	537.45	<b>B694</b>	659.53	<b>B950</b>	784.25
<b>B183</b>	418.46	<b>B439</b>	537.92	<b>B695</b>	660.02	<b>B951</b>	784.75
<b>B184</b>	418.92	<b>B440</b>	538.39	<b>B696</b>	660.50	<b>B952</b>	785.24
<b>B185</b>	419.38	<b>B441</b>	538.86	<b>B697</b>	660.98	<b>B953</b>	785.73
<b>B186</b>	419.85	<b>B442</b>	539.34	<b>B698</b>	661.46	<b>B954</b>	786.22
<b>B187</b>	420.31	<b>B443</b>	539.81	<b>B699</b>	661.94	<b>B955</b>	786.72
<b>B188</b>	420.77	<b>B444</b>	540.28	<b>B700</b>	662.43	<b>B956</b>	787.21
<b>B189</b>	421.23	<b>B445</b>	540.75	<b>B701</b>	662.91	<b>B957</b>	787.70
<b>B190</b>	421.69	<b>B446</b>	541.22	<b>B702</b>	663.39	<b>B958</b>	788.19
<b>B191</b>	422.15	<b>B447</b>	541.70	<b>B703</b>	663.87	<b>B959</b>	788.69
<b>B192</b>	422.62	<b>B448</b>	542.17	<b>B704</b>	664.36	<b>B960</b>	789.18
<b>B193</b>	423.08	<b>B449</b>	542.64	<b>B705</b>	664.84	<b>B961</b>	789.67
<b>B194</b>	423.54	<b>B450</b>	543.11	<b>B706</b>	665.32	<b>B962</b>	790.17
<b>B195</b>	424.00	<b>B451</b>	543.58	<b>B707</b>	665.80	<b>B963</b>	790.66
<b>B196</b>	424.46	<b>B452</b>	544.06	<b>B708</b>	666.29	<b>B964</b>	791.15
<b>B197</b>	424.93	<b>B453</b>	544.53	<b>B709</b>	666.77	<b>B965</b>	791.64
<b>B198</b>	425.39	<b>B454</b>	545.00	<b>B710</b>	667.25	<b>B966</b>	792.14
<b>B199</b>	425.85	<b>B455</b>	545.47	<b>B711</b>	667.73	<b>B967</b>	792.63
<b>B200</b>	426.31	<b>B456</b>	545.95	<b>B712</b>	668.22	<b>B968</b>	793.12
<b>B201</b>	426.77	<b>B457</b>	546.42	<b>B713</b>	668.70	<b>B969</b>	793.62
<b>B202</b>	427.24	<b>B458</b>	546.89	<b>B714</b>	669.18	<b>B970</b>	794.11
<b>B203</b>	427.70	<b>B459</b>	547.36	<b>B715</b>	669.67	<b>B971</b>	794.60
<b>B204</b>	428.16	<b>B460</b>	547.84	<b>B716</b>	670.15	<b>B972</b>	795.10
<b>B205</b>	428.62	<b>B461</b>	548.31	<b>B717</b>	670.63	<b>B973</b>	795.59
<b>B206</b>	429.09	<b>B462</b>	548.78	<b>B718</b>	671.11	<b>B974</b>	796.08
<b>B207</b>	429.55	<b>B463</b>	549.25	<b>B719</b>	671.60	<b>B975</b>	796.58
<b>B208</b>	430.01	<b>B464</b>	549.73	<b>B720</b>	672.08	<b>B976</b>	797.07
<b>B209</b>	430.47	<b>B465</b>	550.20	<b>B721</b>	672.56	<b>B977</b>	797.56
<b>B210</b>	430.94	<b>B466</b>	550.67	<b>B722</b>	673.05	<b>B978</b>	798.06
<b>B211</b>	431.40	<b>B467</b>	551.15	<b>B723</b>	673.53	<b>B979</b>	798.55
<b>B212</b>	431.86	<b>B468</b>	551.62	<b>B724</b>	674.01	<b>B980</b>	799.04
<b>B213</b>	432.32	<b>B469</b>	552.09	<b>B725</b>	674.50	<b>B981</b>	799.54
<b>B214</b>	432.79	<b>B470</b>	552.57	<b>B726</b>	674.98	<b>B982</b>	800.03
<b>B215</b>	433.25	<b>B471</b>	553.04	<b>B727</b>	675.46	<b>B983</b>	800.52
<b>B216</b>	433.71	<b>B472</b>	553.51	<b>B728</b>	675.95	<b>B984</b>	801.02
<b>B217</b>	434.17	<b>B473</b>	553.98	<b>B729</b>	676.43	<b>B985</b>	801.51
<b>B218</b>	434.64	<b>B474</b>	554.46	<b>B730</b>	676.91	<b>B986</b>	802.00
<b>B219</b>	435.10	<b>B475</b>	554.93	<b>B731</b>	677.40	<b>B987</b>	802.50
<b>B220</b>	435.56	<b>B476</b>	555.40	<b>B732</b>	677.88	<b>B988</b>	802.99
<b>B221</b>	436.03	<b>B477</b>	555.88	<b>B733</b>	678.36	<b>B989</b>	803.49
<b>B222</b>	436.49	<b>B478</b>	556.35	<b>B734</b>	678.85	<b>B990</b>	803.98
<b>B223</b>	436.95	<b>B479</b>	556.82	<b>B735</b>	679.33	<b>B991</b>	804.47
<b>B224</b>	437.42	<b>B480</b>	557.30	<b>B736</b>	679.82	<b>B992</b>	804.97
<b>B225</b>	437.88	<b>B481</b>	557.77	<b>B737</b>	680.30	<b>B993</b>	805.46

<b>B226</b>	438.34	<b>B482</b>	558.24	<b>B738</b>	680.78	<b>B994</b>	805.96
<b>B227</b>	438.81	<b>B483</b>	558.72	<b>B739</b>	681.27	<b>B995</b>	806.45
<b>B228</b>	439.27	<b>B484</b>	559.19	<b>B740</b>	681.75	<b>B996</b>	806.94
<b>B229</b>	439.73	<b>B485</b>	559.67	<b>B741</b>	682.23	<b>B997</b>	807.44
<b>B230</b>	440.20	<b>B486</b>	560.14	<b>B742</b>	682.72	<b>B998</b>	807.93
<b>B231</b>	440.66	<b>B487</b>	560.61	<b>B743</b>	683.20	<b>B999</b>	808.43
<b>B232</b>	441.12	<b>B488</b>	561.09	<b>B744</b>	683.69	<b>B1000</b>	808.92
<b>B233</b>	441.59	<b>B489</b>	561.56	<b>B745</b>	684.17	<b>B1001</b>	809.42
<b>B234</b>	442.05	<b>B490</b>	562.03	<b>B746</b>	684.65	<b>B1002</b>	809.91
<b>B235</b>	442.51	<b>B491</b>	562.51	<b>B747</b>	685.14	<b>B1003</b>	810.41
<b>B236</b>	442.98	<b>B492</b>	562.98	<b>B748</b>	685.62	<b>B1004</b>	810.90
<b>B237</b>	443.44	<b>B493</b>	563.46	<b>B749</b>	686.11	<b>B1005</b>	811.39
<b>B238</b>	443.90	<b>B494</b>	563.93	<b>B750</b>	686.59	<b>B1006</b>	811.89
<b>B239</b>	444.37	<b>B495</b>	564.40	<b>B751</b>	687.08	<b>B1007</b>	812.38
<b>B240</b>	444.83	<b>B496</b>	564.88	<b>B752</b>	687.56	<b>B1008</b>	812.88
<b>B241</b>	445.30	<b>B497</b>	565.35	<b>B753</b>	688.04	<b>B1009</b>	813.37
<b>B242</b>	445.76	<b>B498</b>	565.83	<b>B754</b>	688.53	<b>B1010</b>	813.87
<b>B243</b>	446.22	<b>B499</b>	566.30	<b>B755</b>	689.01	<b>B1011</b>	814.36
<b>B244</b>	446.69	<b>B500</b>	566.77	<b>B756</b>	689.50	<b>B1012</b>	814.86
<b>B245</b>	447.15	<b>B501</b>	567.25	<b>B757</b>	689.98	<b>B1013</b>	815.35
<b>B246</b>	447.61	<b>B502</b>	567.72	<b>B758</b>	690.47	<b>B1014</b>	815.85
<b>B247</b>	448.08	<b>B503</b>	568.20	<b>B759</b>	690.95	<b>B1015</b>	816.34
<b>B248</b>	448.54	<b>B504</b>	568.67	<b>B760</b>	691.44	<b>B1016</b>	816.84
<b>B249</b>	449.01	<b>B505</b>	569.15	<b>B761</b>	691.92	<b>B1017</b>	817.33
<b>B250</b>	449.47	<b>B506</b>	569.62	<b>B762</b>	692.41	<b>B1018</b>	817.83
<b>B251</b>	449.94	<b>B507</b>	570.09	<b>B763</b>	692.89	<b>B1019</b>	818.32
<b>B252</b>	450.40	<b>B508</b>	570.57	<b>B764</b>	693.38	<b>B1020</b>	818.82
<b>B253</b>	450.86	<b>B509</b>	571.04	<b>B765</b>	693.86	<b>B1021</b>	819.31
<b>B254</b>	451.33	<b>B510</b>	571.52	<b>B766</b>	694.35	<b>B1022</b>	819.81
<b>B255</b>	451.79	<b>B511</b>	571.99	<b>B767</b>	694.83	<b>B1023</b>	820.30
<b>B256</b>	452.26	<b>B512</b>	572.47	<b>B768</b>	695.32	<b>B1024</b>	820.80