



ENIAC - 2017

XIV Encontro Nacional de Inteligência Artificial e Computacional

Realização:



Organização:



Promoção:





XIV Encontro Nacional de Inteligência Artificial e Computacional
2 a 5 de outubro de 2017
Uberlândia, MG, Brasil

Anais

Comissão Especial de Inteligência Artificial da Sociedade Brasileira de Computação
(CEIA-SBC)

Comissão Especial de Inteligência Computacional da Sociedade Brasileira de
Computação (CEIC-SBC)

COORDENADORES DO COMITÊ DE PROGRAMA

Aline Paes (UFF)
André Britto (UFS)

EDITORES

Aline Paes (UFF)
André Britto (UFS)
Gina M. B. de Oliveira (UFU)

REALIZAÇÃO

Sociedade Brasileira de Computação

ORGANIZAÇÃO

Faculdade de Computação - Universidade Federal de Uberlândia

Redes Neurais Convolucionais Aplicadas ao Processo de Classificação de Cultivares de Guaranazeiros

Alex de Lima Sousa¹, Marcos Filipe Alves Salame²,
Firmino José do Nascimento Filho³, André Luiz Atroch³

¹ Bolsista de Iniciação Científica FAPEAM, ² Analista, ³ Pesquisadores
Embrapa Amazônia Ocidental
Caixa Postal 319 – 69.010-970 – Manaus – AM – Brasil

allexlima@unn.edu.br,
{marcos.salame, firmino.filho, andre.atroch}@embrapa.br

Abstract. *The guarana holds important social and economic value for the Amazon due to its wide use in beverage and cosmetic industries. However, its vulnerability to local fungi and diseases causes a low productivity in the region, which has motivated the creation and availability of cultivars resistant to the main planting impediments, by Embrapa. The distinction of these genetic varieties, however, still depends on manual and technical resources, which are subject to human error. Thus, this work presents a specialized computational agent in the classification of some these cultivars that obtained a accuracy around 97% with a Convolutional Neural Networks model using an own image database.*

Resumo. *O guaranazeiro detém importante valor social e econômico para a Amazônia devido a sua ampla utilização nas indústrias de bebidas e cosméticos. Contudo, sua vulnerabilidade a fungos e doenças locais ocasiona uma baixa produtividade na região, o que tem motivado a criação e disponibilização de cultivares resistentes aos principais empecilhos de plantio, pela Embrapa. A distinção dessas variedades genéticas, entretanto, ainda depende de recursos manuais e técnicos, passíveis de falha humana. Assim, este trabalho apresenta um agente computacional especialista na classificação de alguns desses cultivares que, com o uso de Redes Neurais Convolucionais, obteve uma acurácia em torno de 97% utilizando uma base de imagens própria.*

1. Introdução

O fruto do guaranazeiro (*Paullinia cupana* var. *sorbilis*), o guaraná, devido as suas propriedades energéticas e medicinais, é considerado um importante insumo para indústrias de bebidas e cosméticos, agregando considerável valor socioeconômico para estados que o cultivam, como o Amazonas [Tavares et al. 2005].

Mesmo sendo uma planta originalmente amazônica, a maior concentração espacial de cultivo e produção brasileira do guaraná está na Bahia [IBGE 2015]. Um dos principais motivos que afetam o cultivo de guaranazeiros na Amazônia e incitaram essa migração foi a ausência de uma suficiente diversidade genética resistente a proliferação de pragas e doenças como a antracnose, causada pelo fungo *Colletotrichum guaranicola* [Nascimento Filho et al. 2007].

Esse cenário motivou, no final da década de 70, a Empresa Brasileira de Pesquisa Agropecuária (Embrapa), pela unidade Amazônia Ocidental, iniciar um programa de melhoramento genético do guaranazeiro que objetivava a expansão da produção do guaraná na Amazônia através de pesquisas que, desde 1996, desenvolveram e disponibilizaram 19 cultivares resistentes aos principais fatores bióticos e abióticos que afetam a guaranaicultura na região amazônica [Tricaud et al. 2016].

A quantidade de espécimes desenvolvidos e a variação fenotípica que cada cultivar apresenta ocasionou a elaboração de uma metodologia para distinção desses organismos a partir dos procedimentos esclarecidos no manual intitulado "Instruções para Execução dos Ensaio de Distinguiabilidade, Homogeneidade e Estabilidade de Cultivares de Guaraná (*Paullinia cupana* var. *Sorbilis*)", disponibilizado pelo Ministério da Agricultura, Pecuária e Abastecimento do Brasil em 2010 [MAPA 2010].

Os dispostos que esse manual fornece, entretanto, são restritos a informações técnicas que podem dificultar o processo de distinção dos cultivares caso quem esteja procedendo a análise não tenha alguma familiaridade com botânica ou cultivo do guaraná.

Assim, aliar pesquisa e desenvolvimento de soluções que envolvam a tecnologia da informação, elaborando novas ferramentas que possam auxiliar ou substituir processos difíceis e ainda manuais, como a distinção dos cultivares de guaranazeiros, são alternativas que podem colaborar com produtividade do guaraná no Estado do Amazonas, a médio ou longo prazo.

A utilização técnicas de aprendizado de máquinas para a classificação de plantas a partir de descritores morfológicos como folhas, por exemplo, possuem considerável abundância na literatura em consequência da contribuição importante que o reconhecimento de espécimes vegetais, por sistemas computacionais, oferece ao setor agrônomo e computacional.

Redes Neurais Convolucionais (ou, em inglês, *Convolutional Neural Networks* – CNNs) são consideradas um modelo matemático de classificação inspirado no sistema biológico de processamento de dados visuais. Na literatura, esses algoritmos dispõem de resultados satisfatórios para uma diversidade de problemas, incluindo classificação vegetal [Gu et al. 2015, Jassmann et al. 2015].




Figura 1. Modelo de Rede Neural Artificial Convolucional *LeNet* e suas fases de processamento ilustrando o processo de classificação de cultivares de guaraná. Adaptado de [Vargas et al. 2016].

Diferentemente das redes neurais convencionais, as camadas convolucionais das CNNs, conforme é ilustrado na Figura 1, possuem a responsabilidade de aplicar diversos filtros no dado de entrada, de forma a constituir uma espécie de hierarquia de características que resultam em descritores da imagem precisos [Krizhevsky et al. 2012, Ciresan et al. 2011].

Em contextos de classificação, após as camadas de responsáveis pela extração de características, geralmente é adicionada ao menos uma camada de neurônios artificiais totalmente conectados. Essa fase do processamento, em conjunto com uma função de ativação, é responsável por definir uma conexão entre os filtros executados nas primeiras camadas da rede e a classe do objeto analisado.

Nos trabalhos de [He and Tian 2016] e [Reyes et al. 2015], CNNs são empregadas ao processo de classificação de imagens foliares de diversos espécimes do *dataset Pl@ntView*. O primeiro trabalho conseguiu obter uma acurácia de 86.1% enquanto que o segundo, embora tenha utilizado um modelo pré-treinado com o *dataset ImageNet*, obteve aproximadamente 60% de acurácia. Ambos os trabalhos fizeram uso de imagens com fundos naturais. Provavelmente, essas amostras não tiveram o fundo segmentado devido ao grande volume de imagens nos *datasets* utilizados.

Algumas técnicas de aprendizado de máquina foram aplicadas ao contexto de classificação dos cultivares de guaranazeiros desenvolvidos pela Embrapa, onde observou-se que técnicas de aprendizado profundo, como redes neurais convolucionais, obtiveram uma melhor acurácia em comparação com técnicas clássicas como as árvores de decisão e máquinas de vetores de suporte.

Dessarte, propõe-se a elaboração de uma solução especialista no processo de classificação dos cultivares de guaranazeiros a partir da imagem de uma amostra foliar, utilizando CNNs. Ansiando, assim, a disponibilização de uma ferramenta com fácil utilização, confiável e ágil para auxiliar agricultores e pesquisadores que trabalham com a produção de guaraná na Amazônia, oferecendo uma alternativa às vias atuais de discriminação dos cultivares de guaranazeiros.

2. Material e Métodos

À vista de que os algoritmos de visão computacional e aprendizado de máquina, como as CNNs, podem ter custos computacionais elevados, optou-se por não fazer o emprego desses recursos diretamente em *smartphones*. Assim, almejando também uma arquitetura escalável para a solução proposta, foi-se estabelecido um fluxo para o sistema, conforme Figura 2, tendo como base a metodologia *RESTful*.

2.1. Interface de interação com o usuário e comunicação com o servidor

Um simples *webapp* ficou responsável por fazer o envio da imagem de uma folha do guaranazeiro para o servidor. Esse sistema foi desenvolvido visando ser compatível com dispositivos de diversos sistemas operacionais e tamanhos de telas, a partir de linguagens de marcação *web* com um *back-end* escrito em *javascript*.

Após o usuário capturar ou selecionar, a partir da galeria de imagens, a foto de uma amostra foliar, a aplicação se encarrega de iniciar uma comunicação *ajax* e enviar a imagem codificada em *base64* para o servidor, em uma requisição *POST* formatada com o padrão *json*.




Figura 2. Arquitetura proposta: Após a aquisição da foto, por um dispositivo móvel, a imagem da folha é enviada para um servidor responsável pela classificação e *feedback* da análise.

As requisições ao servidor são gerenciadas por um *RESTful webservice* implementado através da linguagem de programação *Python* em conjunto com as bibliotecas *Flask* e *Flask-RESTful*. No servidor, o sistema foi dividido em dois principais módulos: i) o *webservice*, em si; e ii) o de classificação, incumbido de executar os processos de especificação da imagem submetida, através das CNNs.

2.2. Elaboração do *dataset* e pré-processamento gráfico

Ainda é comum a ausência de estudos relacionados a aprendizagem de máquinas e visão computacional com algumas plantas nativas da Amazônia, como guaranazeiro. Em consequência, bases de imagens dessa vegetação possuem pouca, ou nenhuma, presença em *datasets* públicos como *Pl@ntView*, *Flavia* e o *ImageNet*.

Dessa forma, foi-se necessário a criação de um *dataset* específico para este projeto, com imagens de amostras foliares adultas dos principais cultivares de guaranazeiro. Por ser uma espécie arbustiva e com folhas compostas não tão abundantes, apenas 40 amostras de dois cultivares, no total, foram coletadas em Janeiro e Março de 2017, no campo de guaranazeiros da Embrapa Amazônia Ocidental, na zona rural de Manaus ($2^{\circ}53'39.5''S$ $59^{\circ}58'20.8''W$).

Os cultivares selecionados foram o BRS-Amazonas e BRS-Cereçaporanga, ambos resistentes às principais doenças que atacam guaranazeiros convencionais [Nascimento Filho et al. 1999, Nascimento Filho et al. 2007]. As imagens foram capturadas no mesmo dia de cada coleta, em alta resolução. No mês de Janeiro, foram obtidas 20 fotos, uma de cada amostra, a partir do sensor *Canon EOS 6D*; e em Março, as imagens foram capturas por um sensor *Nikon D7100* em 2 ângulos diferentes, totalizando 40 fotos, nesse mês. Em seguida, as imagens foram organizadas conforme suas classes (BRS-Amazonas e BRS-Cereçaporanga) e validadas por engenheiros agrônomos e pesquisadores especialistas no estudo de guaranazeiros, colaboradores deste trabalho.

O pré-processamento nas imagens baseou-se nos métodos aplicados em trabalhos como os de [Krizhevsky et al. 2012], [Simonyan and Zisserman 2014] e [Reyes et al. 2015]. Assim, cada uma das 60 imagens foram redimensionadas para 224×224 *pixels*, com a folha centralizada no escopo de canais RGB e, diferentemente desses estudos citados, foi possível, devido à pouca quantidade de imagens, realizar a segmentação dos fundos onde as fotografias foram tiradas.




Figura 3. Amostras de imagens presentes no *dataset* elaborado com as duas classes utilizadas no experimento, após o pré-processamento e *data augmentation*.

Com um *dataset* relativamente pequeno, quando comparado a outros trabalhos relacionados, optou-se por aplicar um processo conhecido por *data augmentation*: um recurso amplamente empregado para o avolumamento de *datasets* limitados a uma pequena quantidade de dados e que, também, pode auxiliar a redução de *overfitting*, um dos principais problemas que podem ocorrer durante o treinamento de um classificador [Krizhevsky et al. 2012].

Tabela 1. Distribuição de imagens do *dataset*, gerada aleatoriamente, utilizada no treino e avaliação das arquiteturas de classificação selecionadas.

	Treino		Avaliação		Total
	AlexNet	LeNet	AlexNet	LeNet	
BRS-Amazonas	928	925	472	475	1400
BRS-Cereçaporanga	948	951	452	449	1400
Total	1876 (67%)		924 (33%)		2800

A biblioteca *Keras*, por meio do seu módulo de processamento de imagens, permite a execução da técnica de *data augmentation* criando novas imagens sintéticas a partir de variações randômicas de cada uma das fotografias presentes no *dataset* [Chollet 2015]. Dessa forma, essa biblioteca foi utilizada combinada com os seguintes parâmetros: i) ângulo de 35° para o intervalo de rotação; ii) espelhamento vertical e horizontal; iii) modo de preenchimento constante; iv) 0.01 de o intervalo de zoom; v) 0.2 para a taxa de variação dos canais de cor; e vi) $cval = 0$.

Em consequência, esse processo resultou uma ampliação de, aproximadamente, 46.7 vezes o volume inicial de imagens do *dataset*, com imagens organizadas randomica-

mente seguindo a metodologia *holdout*, conforme explana a Tabela 1. Algumas amostras resultantes da técnica de *data augmentation* são apresentadas na Figura 3.

2.3. Escopo de classificação

Dentre os diversos modelos de implementação das CNNs existentes, a arquitetura *LeNet*, ilustrada na Figura 1, foi introduzida na literatura pelo trabalho de [LeCun et al. 1998] e é considerada um dos primeiros modelos de redes neurais convolucionais, além de possuir uma estrutura simples e pequena quando comparada com arquiteturas mais atuais como a proposta por [Krizhevsky et al. 2012], a *AlexNet*, e a VGG-16.

Dentre os diversos modelos e configurações de treino experimentadas previamente, observou-se que a arquitetura VGG-16 não conseguiu alcançar uma performance satisfatória, obtendo uma acurácia 20% a menos que os modelos LeNet e AlexNet. Devido a esse fator e à sólida profusão na literatura, as arquiteturas apresentadas nos trabalhos [LeCun et al. 1998] e [Krizhevsky et al. 2012] foram selecionadas para serem aplicadas e avaliadas no contexto de classificação de amostras foliares de cultivares do guaranazeiro.

A implementação desses modelos foi realizada com a linguagem de programação *Python*, por meio da biblioteca de *deep learning Keras*, utilizando o *back-end TensorFlow*, além de outras como *NumPy*, *Scikit-learn* e *Scikit-image*. Cada um dos classificadores foram treinados com os seguintes parâmetros: i) 100 épocas de treino; ii) uma taxa de aprendizagem igual a 0.01; e iii) aproximadamente, 1880 imagens, conforme Tabela 1.

O ambiente utilizado para realizar tanto o treinamento quanto as avaliações foi uma instância dedicada no *Google Cloud Platform* com processamento *Intel® Xeon®* de 16 núcleos com 2,6GHz cada, 30GBi de memória RAM e sistema operacional *GNU/Linux Debian*.

3. Resultados e Discussão

O sistema final foi nomeado como WAVA (*Waraná's Automated Visual Analysis*) e apresentou resultados promissores, de forma geral. É possível observar as interfaces gráficas de um protótipo funcional *web* da ferramenta na Figura 3, executado a partir de um dispositivo móvel. A tela presente na Figura 4a dispõe de uma estrutura que comporta o envio ou aquisição da foto de uma amostra foliar do guaranazeiro e a envia para o servidor, onde a análise é, então, realizada. O *feedback* relacionado a classificação da imagem enviada é apresentado pela tela contida na Figura 4b.

Em relação ao módulo de classificação desenvolvido, logo após os treinamentos foi possível realizar os devidos testes com 33% das imagens do *dataset* que resultaram as matrizes de confusão presentes na Figura 5. Essas matrizes são responsáveis por organizar o conjunto de informações classificadas corretamente em suas diagonais principais, conforme é destacado na Figura 6a e 6b, enquanto que os itens classificados de forma errônea são dispostos nas diagonais secundárias.

A matriz de confusão detém considerável relevância por possibilitar o cálculo de métricas como a acurácia, precisão, revocação (ou *recall*) e o *F-Score*, utilizadas comumente para avaliar modelos de classificação. A Tabela 2, por sua vez, apresenta os resultados de algumas dessas métricas para ambas as arquiteturas de CNN.




Figura 4. Telas do WebApp desenvolvido, demonstrando o reconhecimento de uma amostra de teste do dataset.

Figura 5. Matrizes de confusão das arquiteturas de classificação utilizadas.


		Classificado como	
		BRS-Amazonas	BRS-Cereçaporanga
Espécime	BRS-Amazonas	455	17
	BRS-Cereçaporanga	8	444
(a) AlexNet			
		Classificado como	
		BRS-Amazonas	BRS-Cereçaporanga
Espécime	BRS-Amazonas	424	51
	BRS-Cereçaporanga	33	416
(b) LeNet			

O comportamento em relação as taxas de acerto e erro de ambos os modelos utilizados durante o processo de treinamento é representado na Figura 6a e 6b, respectivamente, onde é possível observar uma certa dificuldade de convergência no modelo AlexNet, mesmo este obtendo uma acurácia de 97.3%, nas avaliações. Isso pode ter sido

Tabela 2. Métricas relacionadas a performance de ambos os classificadores.

	Precisão		Revocação		<i>F-Score</i>	
	AlexNet	LeNet	AlexNet	LeNet	AlexNet	LeNet
BRS-Amazonas	0.98	0.93	0.96	0.89	0.97	0.91
BRS-Cereçaporanga	0.96	0.89	0.98	0.93	0.97	0.91
Média	0.97	0.91	0.97	0.91	0.97	0.91

causado em consequência da "profundidade" e robustez que essa arquitetura apresenta, em relação à LeNet. Acredita-se, então, que aumentar a quantidade de épocas do treino desse modelo pode colaborar com uma melhor convergência. A rede LeNet, por outro, lado apresentou uma convergência bem mais ágil alcançando uma acurácia de 90.9%.

**Figura 6. Métricas de treinamento dos modelos de Redes Neurais Convolucionais AlexNet e LeNet.**

Entre as épocas 40 e 65 de treinamento do classificador AlexNet, é possível observar (vide Figura 6) anomalias que podem indicar a presença de *overfitting* neste modelo, mesmo obtendo as melhores métricas nos testes realizados, com uma acurácia de 97.3% contra os 90.9% do modelo LeNet.

4. Conclusões

Nas reuniões realizadas ao longo desse trabalho com pesquisadores que estudam os guarazeiros desenvolvidos pela Embrapa, foi-se observado a importância e as comodidades que a solução proposta neste trabalho pode oferecer, complementando os atuais métodos manuais de distinção dos cultivares.

O desenvolvimento do *dataset* utilizado, com apenas dois espécimes (BRS-Amazonas e BRS-Cereçaporanga) mostrou-se promissor, o que motiva sua ampliação, no futuro, de forma a incluir novas classes além de amostras foliares de mudas. Almeja-se também, distribuí-lo visando contribuir com possíveis trabalhos relacionados a guaranai-cultura, na área de computação e/ou botânica. Não obstante, será importante analisar

melhor o desempenho de novos testes, durante a ampliação do *dataset*, objetivando evitar a possibilidade real de *under* ou *overfitting*. Dessa forma, podendo, inclusive, explorar novas metodologias como a validação cruzada e *fine-tuning*.

Além da necessidade de uma análise mais profusa em relação à possibilidade de *overfitting* neste trabalho, algumas melhorias fazem-se necessárias em uma próxima versão do sistema WAVA como, por exemplo, a agregação de um pré-processamento automatizado que seja responsável pela subtração do *background* das imagens obtidas em ambientes não controlados para reduzir os ruídos para facilitar o processo de classificação.

Ressalta-se também a importância de uma validação, futuramente, em campos de guaranás com agricultores e especialistas da guaranaicultura visando atestar a eficácia da ferramenta proposta neste trabalho que, até então, dispõe apenas de testes experimentais em ambientes controlados. Essa etapa precede as fases finais do projeto, junto da disponibilização de um aplicativo nativo para a plataforma *Google Android*. Com isso, espera-se lançar a solução visando auxiliar o público que atua com a guaranaicultura no Brasil.

5. Agradecimentos

À Fundação de Amparo à Pesquisa do Estado do Amazonas (FAPEAM), pela disponibilização da bolsa de pesquisa; à Empresa Brasileira de Pesquisa Agropecuária (Embrapa) – Amazônia Ocidental, pela infraestrutura disponibilizada; aos colaboradores deste trabalho, os pesquisadores e especialistas em guaranaicultura Firmino José do Nascimento Filho e André Luiz Atroch, cuja disponibilidade e conhecimentos técnicos foram imprescindíveis; e à toda a equipe do Núcleo de Tecnologia da Informação, em especial, ao Sr. Raimundo Barbosa e ao orientador deste projeto, Marcos Filipe Alves Salame.

Referências

- Chollet, F. (2015). Keras. <https://github.com/fchollet/keras>.
- Ciresan, D. C., Meier, U., Masci, J., Maria Gambardella, L., and Schmidhuber, J. (2011). Flexible, high performance convolutional neural networks for image classification. In *IJCAI Proceedings-International Joint Conference on Artificial Intelligence*, volume 22, page 1237. Barcelona, Spain.
- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Liu, T., Wang, X., and Wang, G. (2015). Recent advances in convolutional neural networks. *arXiv preprint arXiv:1512.07108*.
- He, A. and Tian, X. (2016). Multi-organ plant identification with multi-column deep convolutional neural networks. In *Systems, Man, and Cybernetics (SMC), 2016 IEEE International Conference on*, pages 002020–002025. IEEE.
- IBGE (2015). Pesquisa mensal de previsão e acompanhamento das safras agrícolas no ano civil. *Levantamento Sistemático da produção Agrícola*, 29(4):49.
- Jassmann, T. J., Tashakkori, R., and Parry, R. M. (2015). Leaf classification utilizing a convolutional neural network. In *SoutheastCon 2015*, pages 1–3. IEEE.
- Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. In Pereira, F., Burges, C. J. C., Bottou, L., and

- Weinberger, K. Q., editors, *Advances in Neural Information Processing Systems 25*, pages 1097–1105. Curran Associates, Inc.
- LeCun, Y., Bottou, L., Bengio, Y., and Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11):2278–2324.
- MAPA (2010). Instruções para execução dos ensaios de distinguibilidade, homogeneidade e estabilidade de cultivares de guaraná (*Paullinia cupana* var. *Sorbilis*). *República Federativa do Brasil: Diário Oficial da União*.
- Nascimento Filho, F. J., Atroch, A., Pereira, J., and Araújo, J. (2007). Brs-cereçaporanga: nova cultivar para o agronegócio do guaraná. *Embrapa Amazônia Ocidental. Comunicado Técnico*.
- Nascimento Filho, F. J., Atroch, A. L., da Silva Cravo, M., de Macêdo, J. L. V., Garcia, T. B., Júnior, R. C. C., and Ribeiro, J. d. R. C. (1999). *Clones de guaranazeiro para o Estado do Amazonas*. Embrapa Amazônia Ocidental.
- Reyes, A. K., Caicedo, J. C., and Camargo, J. E. (2015). Fine-tuning deep convolutional networks for plant recognition. In *CLEF (Working Notes)*.
- Simonyan, K. and Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *CoRR*, abs/1409.1556.
- Tavares, A., Atroch, A., Nascimento Filho, F. J., Pereira, J., Araújo, J., Moraes, L., et al. (2005). Cultura do guaranazeiro no Amazonas. *Manaus: EMBRAPA Amazônia Ocidental. Sistema de Produção*, 4.
- Tricaud, S., Pinton, F., and Pereira, H. d. S. (2016). Saberes e práticas locais dos produtores de guaraná (*paullinia cupana* kunth var. *sorbilis*) do médio Amazonas: duas organizações locais frente à inovação. *Boletim do Museu Paraense Emílio Goeldi. Ciências Humanas*, 11(1):33–53.
- Vargas, A. C. G., Paes, A., and Vasconcelos, C. N. (2016). Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres. *Conference on Graphics, Patterns and Images (SIBGRAPI)*, 29.