



ConBRepro

XI CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO



EVENTO
ON-LINE

01 a 03
de dezembro 2021

Detecção e classificação de alvéolos em favos de mel utilizando deep learning

Willian O. Pires

Computação – Universidade Tecnológica Federal do Paraná UTFPR

Thiago S. Alves

Computação - Universidade Tecnológica Federal do Paraná UTFPR

Pedro L. De Paula Filho

Computação – Universidade Tecnológica Federal do Paraná UTFPR

Pedro J. S. Rodrigues

Computação – Instituto Politécnico de Bragança IPB

Resumo: A produção de mel é um negócio lucrativo e importante para preservação das abelhas, sendo feito a milhares de anos com apicultura, um processo ainda muito manual e lento. Com objetivo de auxiliar o apicultor no processo e com a evolução de temas como IA, machine Learning e deep learning, tecnologias começaram a surgir e passaram a fazer parte do manejo de colmeias. Esse trabalho apresentar uma revisão sistemática com 15 artigos sobre o tema. A revisão mostrou a estagnação da apicultura na América Latina referente ao mundo e o crescimento de tecnologias aplicadas no manejo de colmeias, que vem se tornando uma ferramenta importante na apicultura.

Palavras-chave: *Apis Mellifera*, Reconhecimento de Imagem, Rede Neural Convolutacional

Detection and classification of cells in honeycombs using deep learning

Abstract: Honey production is a profitable and important business for the preservation of bees, being done thousands of years ago with beekeeping, a process that is still very manual and slow. With the objective of helping the beekeeper in the process and with the evolution of themes such as AI, machine Learning and deep learning, technologies began to emerge and became part of the management of hives. This work presents a systematic review with 15 articles on the subject. The review showed the stagnation of beekeeping in Latin America relative to the world and the growth of technologies applied in the management of hives, which has become an important tool in beekeeping.

Keywords: *Apis Melifera*, Image Recognition, Convolutional Neural Network

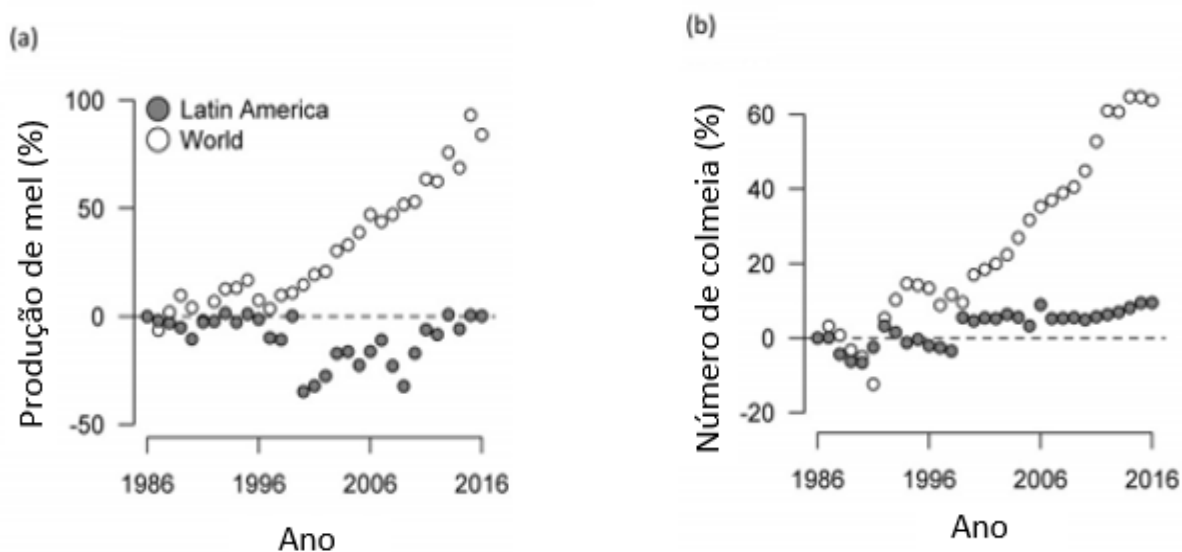
1. Introdução

Um dos alimentos mais antigos do homem, o mel passou por um processo de transformação da forma de sua aquisição e produção, um processo que no início era necessário à procura de enxames de abelhas muitas vezes em locais de difícil acesso, passou por uma evolução até chegar apicultura, um processo mais seguro e eficaz. Atualmente a produção e comercialização de mel se tornou uma atividade bem lucrativa, segundo o IBGE (2019) foram produzidas 45.980.621 toneladas de mel no Brasil, sendo em valor de produção R\$ 493.738 mil reais no ano de 2018.

O mel além do valor alimentar possui características medicinais, devido ao seu efeito antioxidante, antibacteriano e anti-inflamatório, ajudando na redução de tosse e cicatrização de feridas (MEO, Sa *et al.*, 2017, p. 975-978). Atualmente existem 320 variedades de mel em que suas características como cor, cheiro e composição dependem da região de produção, um exemplo é produção de mel no Brasil que possui uma vasta região geográfica que suas características têm impacto no mel, além de utilizar abelhas *apis melífera* africanizadas na produção, mais resistentes a pragas, portanto, não há necessidade de utilização de produtos químicos que contaminam o mel para manter as colmeias (GALHARDO, D. *et. al.*, 2021, p. 247-253).

Mesmo com a importância ambiental e financeira do trabalho da apicultura, a América Latina carece de programas e tecnologia no monitoramento de colmeias. A produção de mel na América Latina encontra-se em um estado de estagnação comparado ao mundo, em 2016 a produtividade de mel na região apresentou um déficit de 460.000 toneladas (Figura 1 - a) e 2016 (Figura 1 - b) apresentou um déficit de 210.000 colmeias em relação ao padrão mundial, muito devido à falta de programas e monitoramento para o apicultor (REQUIER, F. *et al.* 2018, p. 657-662).

Figura 1 – Comparação produção de mel e colmeias em relação américa latina e mundo de 1986 a 2016



Fonte: Adaptado REQUIER, F. (2018)


O apicultor tem um importante papel na manutenção e produtividade de uma colmeia, e sua forma de trabalho varia de região para região e até por países. Um exemplo é a Europa que possui programas de monitoramento de colmeias, auxiliando em boas práticas em tarefas como: Controle químico na colmeia, substituição de favos com cria, substituição de favos por fonte de alimentos, alimentação, Introdução da rainha, distância entre apiário, localização de apiário, tamanho do apiário e tipo de colônia SPERANDIO (2019).

Além da apicultura auxiliar na produção de mel e outros produtos gerados na colmeia como: cera, geleia real, pólen apícola e apitoxina; ela tem importante papel na produção de alimentos, já que abelhas realizam o processo de proliferação, para isso utiliza apicultura migratória, que é o deslocamento da colmeia entre diferentes lugares, o que auxilia no processo de polinização, aumentando a produção agrícola da região proposto por GUIMARAES-CESTARO (2017). Como a apicultura ainda é um processo manual e lento, passaram a surgir tecnologias que auxiliam o apicultor.

2. Tecnologias aplicadas na apicultura

Com o desenvolvimento de novas tecnologias e temas como reconhecimento de imagem, inteligência artificial, machine learning e deep learning começaram a surgir modelos e ferramentas que passaram a ajudar o apicultor em suas tarefas no manejo de colmeias. Um exemplo são tarefas como contagem de alvéolos e avaliação da colmeia, processo lento e que requer experiência do apicultor, graças a evolução do processamento digital de imagem (Figura 2) tarefas como contagem passaram a ser feitas utilizando análise de imagens digitais, um exemplo é o sistema proposto por YOSHIYAMA, M (2011) capaz de contar alvéolos em favos e identificar regiões com pólen armazenado, informações importantes para o apicultor.

Figura 2 – Utilização de imagem para manejo de colmeias




Fonte: Adaptado YOSHIYAMA, M. (2011)

Outro estudo que utilizou imagens foi o projeto apresentado por TAHA (2021) que busca identificar o impacto da idade de um favo dentro de uma colmeia, através de imagens, foram analisadas 20 colmeias de abelhas híbridas *Carniolan*, cada uma com 12.000 abelhas, analisados favos de 1 a 3 anos e entre 4 e 6 anos, concluiu-se que as dimensões das abelhas eram menores em favos mais antigos e também notaram uma menor produtividade nelas, incentivando a troca para favos novos. Com a inclusão de imagens no manejo de colmeias, algumas tarefas não só se tornaram mais rápidas como se tornar um processo que perturba menos as abelhas, já que apenas retira a fotografia, processo rápido, e realiza a análise da imagem, processo mais lento feito em outro local.

O projeto proposto por JEKER (2012) faz utilização de imagens para avaliação de ninhada nos favos, com identificação de alvéolos com fases da vida da larva (ovo, jovem e velha) utilizando reconhecimento de imagem. Outro trabalho que utilizou técnicas de reconhecimento de imagem no manejo de colmeias foi CombCount um script em python que detecta automaticamente favos sem cobertura para acelerar a medição de ninhada e mel na colmeia, o programa é gratuito, e se mostrou 3,2 vezes mais rápido que o Imagej, ferramenta com mesma função, o CombCount utilizou biblioteca de processamento de imagem Opencv (COLIN, T et. al., 2018, p. 10).

O surgimento de áreas como *machine learning* e *deep learning* alteraram métodos e técnicas utilizadas na computação, uma das áreas que mais evoluiu, foi o campo de reconhecimento de imagem, e muitos trabalhos passaram a utilizar essas técnicas no manejo de colmeias. Um exemplo de trabalho é o sistema de monitoramento de colmeias de *apis mellifera* utilizando vídeo de alta resolução em um fundo de favo de mel, para isso foram utilizados modelos de *deep learning* como redes neurais convolucionais para identificar automaticamente as posições dos alvéolos e das ninhadas e a orientação e dimensões do corpo da abelha (Figura 3), o modelo apresentou acurácia 90% na identificação da largura do corpo e 90% na orientação, além disso o modelo conseguiu identificar comportamentos individuais das abelhas que podem ser objeto de estudo (BOZEK, K. et. al., 2021).

Figura 3 – Identificação do corpo da abelha utilizando vídeo



Fonte: Adaptado BOZEK, K. (2021)

Além de utilizar imagens e vídeo para analisar abelhas existem estudos como NGO, T. N. (2021) que desenvolveram um sistema para identificar o comportamento do pólen em uma colmeia, utilizando vídeo em alta resolução, foi desenvolvido um modelo de rede neural convolucional para identificar abelhas *apis mellíferas* portadoras de pólen e não portadoras, o modelo apresentou f1 de 94%, e conclui que alterações do clima como temperatura e luminosidade tiveram impacto na produção do pólen na colmeia. Utilizando vídeo para o manejo de colmeias existem também o projeto proposto por BJERGE, K. (2019) que é um sistema capaz de monitorar infestação de ácaro *Varroa* que destrói colmeias, utilizando gravações de abelhas *apis mellífera* por 5 a 20 minutos, foi desenvolvida uma estrutura para coleta de vídeo e utilizado um modelo de *deep learning*, foram analisados 1.775 abelhas e 98 ácaros, o modelo apresentou uma f1 de 97% para contagem de abelhas e 91% para contagem de ácaros.

Uma importante etapa no monitoramento de colmeias é a identificação de parasitas, o trabalho apresentado por BERKAYA, S. K. (2021) se propõe a identificar além da *Varroa*, outros parasitas como formigas e besouro diferenciando das abelhas, utilizando modelos de *deep learning* aplicados em imagens, ao todo foram utilizadas 19.393 imagens, o modelo apresentou precisão de 99% na identificação de anomalias em colmeias. Outro projeto que faz utilização de *deep learning* é o software open source DeepBee, uma ferramenta que visa auxiliar o apicultor na tarefa de controle de colmeia, desenvolvido no Instituto Politécnico de Bragança, com ele é possível identificar os alvéolos e sua quantidade e classificar em sete classes: ovos, larva, pupa, outros, polén, néctar e mel. Para desenvolver o software foram testadas treze arquiteturas de rede neural, e como critério de escolha foram utilizados além da acurácia do modelo, outros critérios como: tempo de treino, tamanho do modelo, tempo de carregamento em memória do modelo, número de épocas de treino e tempo necessário para classificar 100 imagens. O modelo escolhido foi a Mobilenet que apresentou acurácia de 94,3%, para criar a base o modelo utilizar técnicas de segmentação de imagem e identificação de círculos em imagem (DJEKOUNE, A. O. et. al., 2017, p. 17-31), fazendo uso de bibliotecas como Opencv (ALVES, T. S. et. al., 2020).

O DeepBee disponibiliza uma interface para o apicultor para verifica as sugestões do modelo com as sete classes (separadas por cor), e o número de célula identificadas, caso a sugestão esteja incorreta o software permite realizar a correção e retreinar o modelo (Figura 4).

Figura 4 – Interface do DeepBee



Fonte: ALVES, T. S. (2020)

3. Considerações Finais

Mesmo que o manejo de colmeias e produção de mel seja um negócio lucrativo e importante para o meio ambiente, existe uma estagnação na apicultura realizada na América Latina se comparado ao mundo. Essa diferença de tratamento no processo se deve a incentivo e programas de monitoramento e principalmente a falta de tecnologias aplicadas na apicultura, o que ficou claro na revisão do tema para esse artigo, já que todos os artigos pesquisados que fizeram uso de tecnologias aplicadas na apicultura, foram feitos fora da América Latina. Outra importante conclusão com a revisão do tema, se deve ao crescimento de assuntos como reconhecimento de imagem e *machine learning* aplicados a tarefas do apicultor, muitos utilizando os modelos com resultados próximos de 99% de acurácia, as redes neurais convolucionais. A utilização de modelos mais inteligentes e rápidos tem se mostrado inevitável para tarefas lentas e sujeitas a erro humano, e o manejo de colmeias vem se adaptando as novas tecnologias de reconhecimento de imagem e *machine learning*, mesmo que América Latina esteja atrás do mundo referente a apicultura, essas novas tecnologias se mostram uma boa oportunidade de crescimento para a apicultura da região fazendo uso de conhecimento e aprendizados gerados em outros países.

4. Referências

IBGE. **Produção Agropecuária**. Disponível em: < <https://www.ibge.gov.br/explica/producao-agropecuaria/mel-de-abelha/br> > Acesso em: 09 ago. 2021.

MEO, Sa.; AL-ASIRI, As.; MAHESAR, Al.; ANSARI, Mj.; Role of honey in modern medicine **SAUDI JOURNAL OF BIOLOGICAL SCIENCES**. V. 24 p. 975-978 2017. Disponível em: < https://fac.ksu.edu.sa/sites/default/files/role_of_honey_in_modern_medicine.pdf > Acesso em 27 jun 2021.

GALHARDO, D. GARCIA, R. C. SCHNEIDER, C. R. BRAGA, G. C. CHAMBO, E. D. FRANÇA D. L. B. STROHER, S. M. Physicochemical, bioactive properties and antioxidante of Apis Melifera L. honey from western Paraná, Southern Brazil **Food Science and Technology**. V 41 p. 247-253 2021. Disponível em: < <https://www.scielo.br/j/cta/a/gTRtwRNNpkj3PQzNVNdmWfH/?format=pdf> > Acesso em 27 jun 2021.

REQUIER, F. ANTÚNEZ K. L. MORALES, C. SANCHES, P. CASTILHO, D. GARRIDO, P. Trends in beekeeping and honey bee colony losses in Latin America **Journal of Apicultural Research**. V. 57 p. 657-662 2018. Disponível em: < <https://www.tandfonline.com/doi/abs/10.1080/00218839.2018.1494919?journalCode=tjar20> > Acesso em 27 jun 2021.

SPERANDIO, G. SIMONETTO, A. CARNESECCHI, E. C. C. HATJINA, F. TOSI, S. GILIOLI, G. Beekeeping and honey bee colony health: A review and conceptualization of beekeeping management practices implemented in Europe. **Science of the total environment**. V. 696 2019. Disponível em: < <https://www.sciencedirect.com/science/article/abs/pii/S0048969719337362> > Acesso em 30 jun 2021.

GUIMARAES-CESTARO, L. ALVES, MLTMF. SILVA, MVGB. TEIXEIRA, EW. Honey Bee (Apis Melifera) Health in Stationary and Migratory Apiaries **Sociobiology** V. 64 p. 42-49 2017 Disponível em: < <http://periodicos.uefs.br/ojs/index.php/sociobiology/article/view/1183/0> > Acesso em 30 jun 2021.

YOSHIYAMA, M. KIMURA, K. SAITOH, K. IWATA, H. Measuring colony development in honey bees by simple digital images analysis **Journal of Apicultural Research** V. 50 p. 170-

172 2011 Disponível em: < <https://www.tandfonline.com/doi/abs/10.3896/IBRA.1.50.2.10> >
Acesso em 02 ago 2021.

TAHA, E. K. RAKHA, O. M. ELNABAWY, E. S. M. HASSAN, M. M. SHAWER, D. M. B.
Comb age significantly influences the productivity of the honeybee (*Apis Mellifera*) colony
Saudi Journal of Biological Sciences V. 33 2021. Disponível em: <
<https://www.sciencedirect.com/science/article/pii/S1018364721000975> > Acesso em 04
ago 2021.

JEKER, L. SCHMID, L. MESCHBERGER, T. CANDOLFI, M. PUDENZ, S. MAGYAR, J.
Computer-assisted digital image analysis and evaluation of brood development in honey
bee combs **Journal of Apicultural Research** V. 51 p.63-73 2012. Disponível em: <
<https://www.tandfonline.com/doi/abs/10.3896/IBRA.1.51.1.08> > Acesso em 02 ago 2021.

COLIN, T. BRUCE, J. MEIKLE W. G. BARRON A. B. The development of honey bee
colonies assessed using a new semi-automated brood counting method: Combcount **PloS
ONE** V. 13 p. 10 2018. Disponível em: <
<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6191133/> > Acesso em 03 ago 2021.

BOZEK, K. HEBERT, L. PORTUGAL, Y. STEPHENS G. J. Markerless tracking of na entire
honey bee colony **Nature Communications** V. 12 2021. Disponível em: <
<https://www.nature.com/articles/s41467-021-21769-1> > Acesso em 03 ago 2021.

NGO, T. N. RUSTIA, D. J. A. YANG, E. C. LIN, T. T. Automated monitoring and analyses of
honey bee pollen foraging behavior using a deep learning-based imaging system
Computers and Electronics in Agriculture V. 187 2021. Disponível em: <
<https://www.sciencedirect.com/science/article/abs/pii/S0168169921002568> > Acesso em
04 ago 2021.

BJERGE, K. FRIGAARD, C. E. MIKKELSEN, P. H. NIELSEN, T. H. MISBIH, M. KRYGER, P. A computer vision system to monitor the infestation level of Varroa destructor in a honeybee colony **Computers and Electronics in Agriculture** V. 164 2019. Disponível em: < <https://www.sciencedirect.com/science/article/abs/pii/S0168169918310329> > Acesso em 05 ago 2021.

BERKAYA, S. K. GUNAL, E. S. GUNAL, S. Deep learning-based classification models for beehive monitoring **Ecological Informatics** V. 64 2021. Disponível em: < <https://www.sciencedirect.com/science/article/abs/pii/S1574954121001448> > Acesso em 05 ago 2021.

DJEKOUNE, A. O. MESSAOUDI, K. AMARA, K. Incremental circle hough transform: Na improved method for circle detection **Optik** V. 133 p. 17-31 2017. Disponível em: < <https://www.sciencedirect.com/science/article/abs/pii/S0030402616316175> > Acesso em 04 ago 2021.

ALVES, T. S. PINTO, A. M. VENTURA, P. NEVES, C. J. BIRON, D. G. JUNIOR, A. C. FILHO, P. L. D. P. RODRIGUES, P. J. Automatic detection and classification of honey bee comb cells using deep learning **Computers and Electronics in Agriculture** V. 170 2020. Disponível em: < <https://www.sciencedirect.com/science/article/abs/pii/S0168169919307690> > Acesso em 04 ago 2021.