

A utilização da inteligência artificial na medicina pode ser definida como uma interação multidisciplinar a partir do uso de dados estruturados, conhecimento técnico-científico e modelos matemáticos afim de melhorar a prática dos diversos elementos que compõem o segmento da saúde.

Sua aplicabilidade na área médica é tão ampla e complexa quanto a relação entre esses elementos em diferentes esferas:

- Prestadores de serviços em saúde: exemplos hospitais e laboratórios.
- Organizações voltadas à qualidade: Joint Commission (EUA), NICE (RU), ONA (BR). Querem saber se *guidelines* clínicos trazem os benefícios pretendidos quanto à qualidade, segurança e custo
- Organizações promotoras de evidências: Cochrane. Querem descobrir se um determinado tratamento é superior a outro e compartilhar a informação com a comunidade científica
- Pesquisadores
- Profissionais de saúde
- Cidadãos e pacientes


Todos esses elementos geram e consomem grandes quantidades de informação. Estima-se, atualmente, que o conhecimento médico dobre de volume num **período de poucos anos**. Como manejar todos esses dados gerados em benefício do conhecimento e das práticas clínicas?

A inteligência artificial vem sendo empregada de maneira crescente e promissora para nos auxiliar nesse tipo de solução, em seus diversos ramos, métodos e modelos.

O *machine learning* é a aplicação de modelos matemáticos e geração de algoritmos capazes de “aprender” características de um conjunto de dados, e de estabelecer previsões acerca de outros dados. A partir dele, é possível a separação de um determinado grupo de pessoas em duas ou mais categorias, baseado em características desses indivíduos, criando uma espécie de modelo de previsão, definindo quais pessoas possuem uma doença ou terão um determinado desfecho clínico, por exemplo. Sua utilização é crescente e ampla nos últimos anos, já tendo sido usada para melhoria do diagnóstico do câncer de mama e de ovário em ultrassonografia, prognóstico e classificação de melanomas, retinopatia diabética, susceptibilidade a doença cerebrovascular, doenças da tireoide e recorrência de câncer, bem como no desenvolvimento de habilidades diagnósticas no treinamento médico. Mas a lista de aplicabilidade não para por aí e a todo momento surgem novas aplicações.

*Deep learning* é um método de *machine learning*, que dá às máquinas, entre outros atributos, a capacidade de analisar imagens a elas ofertadas, extraíndo destas imagens, através de um algoritmo de propagação reversa ou *backpropagation*, características específicas (algumas delas não percebidas pela avaliação humana). É como se as máquinas fossem “treinadas” em avaliar aquela determinada classe de imagens. A partir de então, ganham a habilidade de avaliar novas imagens adquiridas prospectivamente, baseadas nas características previamente aprendidas e acumuladas. Para tanto, podem ser utilizados modelos de redes neurais convolucionais (CNN – convolutional neural networks), que simulam em ambiente

computacional a estrutura, interação e funcionamento de neurônios cerebrais. CNNs são tidas como o modelo de melhor resultados no reconhecimento de imagens, pois são capazes de reconhecer nas imagens valores paramétricos importantes e de automaticamente ajustar a relevância destes valores na análise.



Extração de achados

em imagem endoscópica

FONTE: <http://proceedings.spiedigitallibrary.org/proceeding.aspx?doi=10.1117/12.2217148>

**A aplicação desse avanços na endoscopia é naturalmente promissor já que as imagens são a base da nossa atividade.**

O reconhecimento anatômico, por exemplo, já demonstra ser viável através de soluções em IA. Um programa diagnóstico baseado em uma CNN foi treinado com mais de 27.000 imagens em endoscopia alta, sendo as imagens categorizadas em 4 segmentos anatômicos: laringe, esôfago, estômago e duodeno; além de três segmentos em imagens do estômago (proximal, médio e distal). Curvas ROC e as respectivas áreas sob a curva demonstraram bom desempenho no diagnóstico dos segmento (tabela 1)

Segmento	Área sob curva
Laringe	1.00
Esôfago	1.00
Estômago	0.99
Proximal	0.99
Médio	0.99
Distal	0.99
Duodeno	0.99

Tabela 1 – Áreas sob curva ROC. Reconhecimento anatômico.


## Esôfago de Barrett

Mesmo quando a imagem não é o objeto principal de estudo, existem exemplos da aplicação de IA em endoscopia. *Machine Learning* foi utilizado na construção de uma árvore de decisão para a predição de displasia em esôfago de Barrett, baseada na avaliação de endoscopistas *experts*, que examinaram 40 vídeos de 60 segundos obtidos em pacientes em seguimento endoscópico por Barrett (17 com displasia e 23 sem displasia). Este algoritmo foi utilizado no treinamento de endoscopistas de menor experiência e foi capaz de aumentar a acurácia da predição feita por não *experts*, apontando uma aplicabilidade da IA no ensino e treinamento médico.

### *H. pylori*

Embora existam formas mais objetivas de realizar pesquisa de *H. pylori*, como o teste de urease e estudo anatomopatológico, por exemplo, sabe-se que achados endoscópicos, como atrofia, enantema difuso, edema, alargamento de pregas e nodularidade mucosa podem sugerir a presença da bactéria, enquanto o arranjo regular de vênulas coletoras e pólipos de glândulas fúndicas são características de uma mucosa livre de *H. pylori*.

A aplicação de uma rede neural convolucional treinada com 32.208 imagens endoscópicas, com casos *H. pylori* positivos e negativos, obteve acurácia significativamente superior à performance de 23 endoscopistas incluídos no estudo, embora suas sensibilidade e especificidade tenham sido comparáveis.




Exemplos de aspecto endoscópico em paciente com *H. pylori* e sem *H. pylori*  
FONTE: Shichijo S, et al. EBioMedicine [Internet]. 2017 Nov;25:106–11.

### **Câncer gástrico**

No início do ano, um grupo japonês descreveu a habilidade de um sistema diagnóstico baseado em CNN,

treinado com mais de 13.000 imagens endoscópicas de 2639 lesões gástricas com confirmação histológica de adenocarcinoma gástrico. Para avaliar a acurácia do sistema em diagnosticar corretamente novas lesões, o sistema foi desafiado a analisar outro conjunto de imagens de 69 pacientes com 77 lesões neoplásicas. O sistema foi capaz de detectar 92,2% dos cânceres, incluindo pequenas lesões intramucosas de difícil detecção. Todas as lesões invasivas foram detectadas. Apenas seis lesões deixaram de ser diagnosticadas e tratavam-se de lesões diferenciadas intramucosas, de aspecto semelhante a áreas de gastrite, na avaliação dos autores. Por outro lado, 69,4% das lesões diagnosticadas pelo sistema como câncer gástrico eram benignas. Os autores ponderam que mais grave seriam os falso negativos e que o valor preditivo positivo de 30,6% alcançado pelo sistema é clinicamente aceitável. Comentam ainda que a capacidade de aprendizado adicional da rede neural permitirá a correção da baixa especificidade no futuro.



FONTE: Hirasawa T, Aoyama K, Tanimoto T, Ishihara S, Shichijo S, Ozawa T, et al. *Gastric Cancer* 2018;21(4):653–60.

### **Pólipos e câncer colorretal**

Dada a importância da detecção de adenomas colorretais na prevenção dos CCR e a potencialidade da inteligência artificial no reconhecimento de imagens, os recursos de CNN têm sido descritos também no apoio à detecção e até mesmo classificação de pólipos colorretais. Estima-se que cerca de 26% de pólipos pequenos deixem de ser diagnosticados em colonoscopias e embora tenham descrições objetivas, os sistemas propostos de classificação das lesões ainda guardam considerável discordância inter-observador. Nos últimos anos, vários estudos têm demonstrado a viabilidade da utilização de ferramentas de apoio em tempo real, com desempenho comparável ao humano, ampliando a capacidade da colonoscopia na prevenção de CCR, bem como auxiliando na tomada de decisão terapêutica.

**Soluções em IA previamente utilizadas fora do âmbito de saúde foram utilizadas na diferenciação macroscópica entre pólipos adenomatosos e hiperplásicos, com acurácia superior à humana. Também está descrita a classificação automática do padrão de criptas segundo a classificação de Kudo.**

Indo além da análise de imagens, um modelo de detecção de câncer colorretal foi desenvolvido a partir de

dados demográficos e hemogramas completos prévios ao diagnóstico do câncer colorretal (CCR) numa população ligada a um amplo registro de dados de saúde regional nos EUA. O modelo foi capaz de identificar antecipadamente indivíduos com risco até 10 vezes maior de ter formas curáveis de CCR, com melhor acurácia em tumores do cólon direito. Este estudo indica a possibilidade do uso de *machine learning* na melhoria e maior assertividade de programas de rastreamento do CCR a partir de dados estruturados em populações alvo.

### **Inteligência artificial tem se mostrado útil também como apoio à tomada de decisão na estratégia terapêutica em câncer colorretal.**

Um estudo japonês analisou retrospectivamente dados de 690 pacientes consecutivos com CCR T1 ressecados endoscopicamente de 2001 a 2016. 590 deles foram submetidos a um modelo de *machine learning* e os demais 100 casos foram incluídos para validação do modelo. Na análise, foram considerados 45 fatores clínico-patológicos, dentre eles testes sanguíneos, marcadores tumorais, achados morfológicos e histológicos e dados demográficos, para predição de metástase linfonodal. Sensibilidade, especificidade e acurácia do modelo foram calculadas e comparadas às dos *guidelines* americano, europeu e japonês. Os resultados apontam que o uso deste modelo de inteligência artificial reduziria significativamente a indicação desnecessária de cirurgia adicional após ressecção endoscópica nestes pacientes.

Ainda que a utilização das soluções de IA na área endoscópica seja incipiente e muitos dos trabalhos aqui comentados tenham sido publicados em revistas fora de periódicos da área médica, sua aplicação pode trazer mudanças de paradigma no conhecimento médico e na redefinição de papéis e estratégias na prática endoscópica.

### **Referências bibliográficas:**

1. Ichimasa K, Kudo SE, Mori Y, Misawa M, Matsudaira S, Kouyama Y, et al. Artificial intelligence may help in predicting the need for additional surgery after endoscopic resection of T1 colorectal cancer. *Endoscopy*. 2018;50(3):230–40.
2. Misawa M, Kudo S ei, Mori Y, Cho T, Kataoka S, Yamauchi A, et al. Artificial Intelligence-Assisted Polyp Detection for Colonoscopy: Initial Experience. *Gastroenterology* [Internet]. The American Gastroenterological Association; 2018;154(8):2027–2029.e3. Available from: <https://doi.org/10.1053/j.gastro.2018.04.003>
3. Shichijo S, Nomura S, Aoyama K, Nishikawa Y, Miura M, Shinagawa T, et al. Application of Convolutional Neural Networks in the Diagnosis of Helicobacter pylori Infection Based on Endoscopic Images. *EBioMedicine* [Internet]. 2017 Nov;25:106–11. Available from: <https://linkinghub.elsevier.com/retrieve/pii/S2352396417304127>
4. Ahmad J, Muhammad K, Lee MY, Baik SW. Endoscopic Image Classification and Retrieval using Clustered Convolutional Features. *J Med Syst* [Internet]. *Journal of Medical Systems*; 2017 Dec 30;41(12):196. Available from: <http://link.springer.com/10.1007/s10916-017-0836-y>
5. Hirasawa T, Aoyama K, Tanimoto T, Ishihara S, Shichijo S, Ozawa T, et al. Application of artificial intelligence using a convolutional neural network for detecting gastric cancer in endoscopic images. *Gastric Cancer* [Internet]. Springer Japan; 2018;21(4):653–60. Available

from: <https://doi.org/10.1007/s10120-018-0793-2>

6. Sehgal V, Rosenfeld A, Graham DG, Lipman G, Bisschops R, Rangunath K, et al. Machine Learning Creates a Simple Endoscopic Classification System that Improves Dysplasia Detection in Barrett's Oesophagus amongst Non-expert Endoscopists. *Gastroenterol Res Pract* [Internet]. 2018 Aug 29;2018(Suppl 1):1–9. Available from: <http://gut.bmj.com/lookup/doi/10.1136/gutjnl-2016-312388.532>
7. Hornbrook MC, Goshen R, Choman E, O'Keeffe-Rosetti M, Kinar Y, Liles EG, et al. Early Colorectal Cancer Detected by Machine Learning Model Using Gender, Age, and Complete Blood Count Data. *Dig Dis Sci*. Springer US; 2017;62(10):2719–27.
8. Ribeiro E, Uhl A, Wimmer G, Häfner M. Exploring Deep Learning and Transfer Learning for Colonic Polyp Classification. *Comput Math Methods Med* [Internet]. 2016;2016:1–16. Available from: <https://www.hindawi.com/journals/cmml/2016/6584725/>
9. Brandao P, Mazomenos E, Ciuti G, Caliò R, Bianchi F, Menciassi A, et al. Fully convolutional neural networks for polyp segmentation in colonoscopy. In: Armato SG, Petrick NA, editors. 2017. p. 101340F. Available from: <http://proceedings.spiedigitallibrary.org/proceeding.aspx?doi=10.1117/12.2254361>
10. Billah M, Waheed S, Rahman MM. An Automatic Gastrointestinal Polyp Detection System in Video Endoscopy Using Fusion of Color Wavelet and Convolutional Neural Network Features. *Int J Biomed Imaging* [Internet]. 2017;2017:1–9. Available from: <https://www.hindawi.com/journals/ijbi/2017/9545920/>
11. Takiyama H, Ozawa T, Ishihara S, Fujishiro M, Shichijo S, Nomura S, et al. Automatic anatomical classification of esophagogastroduodenoscopy images using deep convolutional neural networks. *Sci Rep* [Internet]. 2018 Dec 14;8(1):7497. Available from: <http://www.nature.com/articles/s41598-018-25842-6>
12. Park SY, Sargent D. Colonoscopic polyp detection using convolutional neural networks. In: Tourassi GD, Armato SG, editors. 2016. p. 978528. Available from: <http://proceedings.spiedigitallibrary.org/proceeding.aspx?doi=10.1117/12.2217148>

