Dirigido por Adam Bohr y Kaveh Memarzadeh

Inteligencia artificial en el ámbito de la salud

ELSEVIER

Inteligencia artificial en el ámbito de la salud

Propiedad de Elsevier
Prohibida su reproducción y venta

C0070.indd i 16/07/21 10:19 AM

Propiedad de Elsevier
Prohibida su reproducción y venta

C0070.indd ii 16/07/21 10:19 AM

Inteligencia artificial en el ámbito de la salud

Propiedad de Elsevier
Prohibida su reproducción y venta

Dirigido por

ADAM BOHR
CEO and Co-Founder of Sonohaler, Copenhagen, Denmark

KAVEH MEMARZADEH
Commercial Field Application Scientist at ChemoMetec, Lillerød, Denmark

ELSEVIER

ACADEMIC PRESS
An imprint of Elsevier

ELSEVIER

Avda. Josep Tarradellas, 20-30, 1.°, 08029, Barcelona, España

Artificial Intelligence in Healthcare
Copyright © 2020 by Elsevier, Inc. All rights reserved.
ISBN: 978-0-12-818438-7

This translation of *Artificial Intelligence in Healthcare* by Adam Bohr and Kaveh Memarzadeh was undertaken by Elsevier España, S.L.U. and is published by arrangement with Elsevier, Inc.

Esta traducción de *Artificial Intelligence in Healthcare,* de Adam Bohr y Kaveh Memarzadeh, ha sido llevada a cabo por Elsevier España, S.L.U. y se publica con el permiso de Elsevier, Inc.

Inteligencia artificial en el ámbito de la salud, de Adam Bohr y Kaveh Memarzadeh.
© 2022 Elsevier España, S.L.U.
ISBN: 978-84-1382-017-0
eISBN: 978-84-1382-106-1

Todos los derechos reservados.

Reserva de derechos de libros
Cualquier forma de reproducción, distribución, comunicación pública o transformación de esta obra solo puede ser realizada con la autorización de sus titulares, salvo excepción prevista por la ley. Diríjase a CEDRO (Centro Español de Derechos Reprográficos) si necesita fotocopiar o escanear algún fragmento de esta obra (www.conlicencia.com; 91 702 19 70/93 272 04 45).

Advertencia
Esta traducción ha sido llevada a cabo por Elsevier España, S.L.U. bajo su única responsabilidad. Facultativos e investigadores deben siempre contrastar con su propia experiencia y sus conocimientos el uso de cualquier información, método, compuesto o experimento descritos aquí. Los rápidos avances en medicina requieren que los diagnósticos y las dosis de fármacos recomendadas sean siempre verificados personalmente por el facultativo. Con todo el alcance de la ley, ni Elsevier, ni los autores, los editores o los colaboradores asumen responsabilidad alguna por la traducción ni por los daños que pudieran ocasionarse a personas o propiedades por el uso de productos defectuosos o negligencia, o como consecuencia de la aplicación de métodos, productos, instrucciones o ideas contenidos en esta obra.

Revisión científica:
Enrique Puertas Sanz
Director del Máster Universitario en Big Data Analytics, Universidad Europea (Madrid).

Juan José Beunza Nuin
Profesor titular de Salud Pública y Educación Interprofesional, director del grupo de investigación Machine Learning Salud-UEM y director del Programa de Educación Interprofesional y Práctica Colaborativa de la Facultad de Ciencias Biomédicas y de la Salud, Universidad Europea (Madrid).

Borja Rodríguez Vila
Profesor titular de Procesamiento de la Señal y coordinador del Grado en Ingeniería Biomédica, Universidad Europea (Madrid).

Servicios editoriales: DRK Edición
Depósito legal: B. 12.553-2021
Impreso en España

Propiedad de Elsevier
Prohibida su reproducción y venta

Nota de respaldo

La inteligencia artificial está mejorando cada vez más la atención de los pacientes y la asistencia sanitaria a nivel mundial. La demanda sin precedentes de servicios médicos implica que debemos aprovechar las nuevas herramientas de forma rápida, segura y eficaz. Este libro aborda de una manera clara y exhaustiva la situación actual y lo que se puede conseguir en un futuro próximo.

Dr. Umang Patel
Director, NHS Services, Babylon Health

Propiedad de Elsevier
Prohibida su reproducción y venta

Propiedad de Elsevier
Prohibida su reproducción y venta

Índice de capítulos

Colaboradores *XI*
Sobre los directores *XIII*
Biografías *XV*
Prólogo *XIX*
Introducción *XXI*

1. La asistencia sanitaria actual, los datos masivos y el aprendizaje automático **1**

Adam Bohr y Kaveh Memarzadeh

1.1 La práctica sanitaria actual 1
1.2 Tratamientos y servicios asistenciales basados en valores 5
1.3 Aumento del volumen de datos en la asistencia sanitaria 10
1.4 Análisis de los datos sanitarios (aprendizaje automático y aprendizaje profundo) 16
1.5 Conclusiones/resumen 21
Bibliografía 22

2. El auge de la inteligencia artificial en las aplicaciones sanitarias **25**

Adam Bohr y Kaveh Memarzadeh

2.1 La nueva era de la asistencia sanitaria 25
2.2 Medicina de precisión 28
2.3 Inteligencia artificial y visualización médica 33
2.4 Historias clínicas personales inteligentes 38
2.5 Robótica y dispositivos alimentados por inteligencia artificial 43
2.6 Vida cotidiana asistida por el entorno 46
2.7 La inteligencia artificial puede verle ahora 51
Bibliografía 57

3. Descubrimiento de fármacos y modelado molecular mediante inteligencia artificial **61**

Henrik Bohr

3.1 Introducción. Ámbito de la inteligencia artificial en el descubrimiento de fármacos 61
3.2 Diversos tipos de aprendizaje automático en inteligencia artificial 64
3.3 Modelado molecular y bases de datos en inteligencia artificial para moléculas de fármacos 70
3.4 Métodos de AA de mecánica computacional en el modelado molecular 72
3.5 Caracterización del fármaco mediante superficies de isopotencial 74

Propiedad de Elsevier
Prohibida su reproducción y venta

C0085.indd VII 16/07/21 10:34 AM

3.6 Diseño de fármacos para neurorreceptores mediante técnicas de redes neuronales artificiales 75
3.7 Uso específico del aprendizaje profundo en el diseño de fármacos 78
3.8 Posible desarrollo futuro de la inteligencia artificial en el diseño y el desarrollo de fármacos 80
Bibliografía 81

4. Aplicaciones de la inteligencia artificial en la administración y el desarrollo de fármacos 85

Stefano Colombo

4.1 El campo farmacéutico en evolución 85
4.2 Administración de fármacos y nanotecnología 90
4.3 I + D de calidad por diseño 92
4.4 Inteligencia artificial en el modelado de la administración de fármacos 95
4.5 Aplicación de la inteligencia artificial en la I + D de productos farmacéuticos 100
4.6 Panorama de la implementación de la IA en la industria de la administración de medicamentos 109
4.7 Conclusión: el camino a seguir 111
Bibliografía 112

5. Decisiones de diagnóstico y tratamiento del cáncer mediante inteligencia artificial 117

Reza Mirnezami

5.1 Antecedentes 117
5.2 Inteligencia artificial, aprendizaje automático y aprendizaje profundo en el cáncer 119
5.3 Inteligencia artificial para determinar la susceptibilidad al cáncer 122
5.4 Inteligencia artificial para mejorar el diagnóstico y la estadificación del cáncer 125
5.5 Inteligencia artificial para predecir la respuesta al tratamiento del cáncer 127
5.6 Inteligencia artificial para predecir la recurrencia y la supervivencia del cáncer 130
5.7 Inteligencia artificial para la farmacoterapia personalizada del cáncer 133
5.8 ¿Cómo afectará la inteligencia artificial a las prácticas éticas y a los pacientes? 136
5.9 Observaciones finales 138
Bibliografía 140

6. Inteligencia artificial para la imagen médica 143

Khanhvi Tran, Johan Peter Bøtker, Arash Aframian y Kaveh Memarzadeh

6.1 Introducción 143
6.2 Resultados de la inteligencia artificial en radiología/imágenes médicas 144
6.3 Usar la inteligencia artificial en radiología y superar sus obstáculos 146

Propiedad de Elsevier
Prohibida su reproducción y venta

6.4 Rayos X e inteligencia artificial en imágenes médicas: caso 1 (Zebra medical vision) 151
6.5 Ultrasonidos e inteligencia artificial en imágenes médicas: caso 2 (Butterfly iQ) 156
6.6 Aplicación de la inteligencia artificial en imágenes médicas: caso 3 (Arterys) 158
6.7 Perspectivas 160
Bibliografía 161

7. Dispositivos médicos e inteligencia artificial 163
Arash Aframian, Farhad Iranpour y Justin Cobb

7.1 Introducción 163
7.2 El desarrollo de la inteligencia artificial en los dispositivos médicos 163
7.3 Limitaciones de la inteligencia artificial en dispositivos médicos 171
7.4 Las futuras fronteras de la inteligencia artificial en los dispositivos médicos 172
Bibliografía 174

8. Cirugía asistida por inteligencia artificial 179
Elan Witkowski y Thomas Ward

8.1 Introducción 179
8.2 Preoperatorio 179
8.3 Intraoperatorio 185
8.4 Postoperatorio 193
8.5 Conclusión 196
Bibliografía 197
Otras lecturas 201

9. Monitorización remota de pacientes mediante inteligencia artificial 203
Zineb Jeddi y Adam Bohr

9.1 Introducción a la monitorización remota de pacientes 203
9.2 Implementación de la monitorización de pacientes 205
9.3 El papel de la inteligencia artificial en la monitorización remota de pacientes 209
9.4 Predicción y seguimiento de la diabetes mediante inteligencia artificial 219
9.5 Monitorización cardiaca mediante inteligencia artificial 221
9.6 Aplicaciones neuronales de la inteligencia artificial y la monitorización remota de pacientes 224
9.7 Conclusiones 229
Bibliografía 230

Propiedad de Elsevier
Prohibida su reproducción y venta

10. Aspectos de seguridad, privacidad e intercambio de información en la inteligencia artificial aplicada a la salud 235

Jakub P. Hlávka

10.1 Introducción a la seguridad y la privacidad digitales 235
10.2 Preocupaciones por la seguridad y la privacidad en la inteligencia artificial sanitaria 237
10.3 Riesgos y oportunidades de la inteligencia artificial en la privacidad de los datos 246
10.4 Abordar las amenazas a los sistemas y datos de salud en la era de la inteligencia artificial 253
10.5 Definición de respuestas óptimas a los desafíos de seguridad, privacidad e intercambio de información en la inteligencia artificial sanitaria 256
10.6 Conclusiones 264
Agradecimientos 265
Bibliografía 266

11. El impacto de la inteligencia artificial en los seguros de salud 271

Rajeev Dutt

11.1 Panorama de la industria de los seguros de salud a nivel mundial 271
11.2 Principales desafíos que enfrenta la industria de los seguros de salud 272
11.3 La aplicación de la inteligencia artificial en la industria de los seguros de salud 274
11.4 Estudio de casos 280
11.5 Preocupaciones morales, éticas y regulatorias relativas al uso de la inteligencia artificial 280
11.6 Las limitaciones de la inteligencia artificial 282
11.7 El futuro de la inteligencia artificial en la industria de los seguros de salud 289
Bibliografía 290

12. Desafíos éticos y legales en la atención sanitaria basada en la inteligencia artificial 295

Sara Gerke, Timo Minssen y Glenn Cohen

12.1 Entendiendo la inteligencia artificial 296
12.2 Tendencias y estrategias 296
12.3 Desafíos éticos 300
12.4 Retos legales 306
12.5 Conclusión 327
Agradecimientos 328
Bibliografía 328

Observaciones finales *337*
Índice alfabético *339*

Propiedad de Elsevier
Prohibida su reproducción y venta

Colaboradores

Arash Aframian
Trauma and Orthopaedics, Imperial College London, London, United Kingdom
NHS, London, United Kingdom

Adam Bohr
Sonohaler, Copenhagen, Denmark

Henrik Bohr
Chemical Engineering, Technical University of Denmark, Lyngby, Denmark

Johan Peter Bøtker
Department of Pharmacy, University of Copenhagen, Copenhagen, Denmark

Justin Cobb
Professor and the Chair of Orthopedics at Imperial College London, London, United Kingdom

Glenn Cohen
Harvard Law School, Cambridge, MA, United States

Stefano Colombo
Independent Scientist, Leon, Spain

Rajeev Dutt
AI Dynamics Inc., Redmond, WA, United States

Sara Gerke
The Petrie-Flom Center for Health Law Policy, Biotechnology, and Bioethics at Harvard Law School, The Project on Precision Medicine, Artificial Intelligence, and the Law (PMAIL), Harvard University, Cambridge, MA, United States

Jakub P. Hlavka
Health Policy and Management Department of the Price School of Public Policy and Schaeffer Center for Health Policy & Economics, University of Southern California, Los Angeles, CA, United States

Farhad Iranpour
Trauma and Orthopedic Surgeon, Imperial College London, London, United Kingdom

Zineb Jeddi
TICLab, International University of Rabat (UIR), Rabat, Morocco
National Institute of Statistics and Applied Economics (INSEA), Rabat, Morocco

Kaveh Memarzadeh
ChemoMetec, Lillerød, Denmark

Timo Minssen
Centre for Advanced Studies in Biomedical Innovation Law (CeBIL), University of Copenhagen, Copenhagen, Denmark

Reza Mirnezami
Department of Surgery and Cancer, Imperial College London, London, United Kingdom

Propiedad de Elsevier
Prohibida su reproducción y venta

C0090.indd XI 16/07/21 10:30 AM

Khanhvi Tran
Sonohaler, Copenhagen, Denmark

Thomas Ward
Department of Surgery, Massachusetts General Hospital/Harvard Medical School, Boston, MA, United States

Elan Witkowski
Department of Surgery, Massachusetts General Hospital/Harvard Medical School, Boston, MA, United States

Propiedad de Elsevier
Prohibida su reproducción y venta

Sobre los directores

Adam Bohr, PhD, es el director ejecutivo y cofundador de Sonohaler, una compañía de dispositivos médicos y sanitarios centrada en el control del asma a través de señales acústicas y herramientas de autoaprendizaje. También es cofundador de Zerion ApS, una compañía que aspira a transformar el panorama farmacéutico con la formulación de fármacos poco solubles. Con anterioridad, ha sido profesor adjunto en el Departamento de Farmacia de la University of Copenhagen (Dinamarca), donde investigó sobre implantes de fármacos, nanomedicina y tecnología de microfluidos, e impartió clases sobre tecnología farmacéutica. Ha publicado aproximadamente cincuenta artículos académicos revisados por pares y capítulos de libros, y se doctoró en Ingeniería Biomédica por el University College London (Reino Unido). Es un visionario de la salud y un defensor de la inteligencia artificial en la asistencia sanitaria apasionado de las tecnologías sanitarias centradas en el paciente.

Propiedad de Elsevier
Prohibida su reproducción y venta

Kaveh Memarzadeh, PhD, es un científico dedicado actualmente al ámbito comercial de aplicaciones en Chemo-Metec, una compañía biotecnológica centrada en la innovación en el campo de la citometría celular automatizada. Ha supervisado la gestión de la investigación y la comunicación en Orthopaedic Research UK (ORUK), una organización benéfica que financia proyectos para la mejora y el desarrollo de la ortopedia. Ha publicado numerosos artículos académicos revisados por pares y se doctoró en Nanotecnología, Biomateriales y Microbiología. También es profesor invitado en el University College London (Reino Unido), donde enseña sobre el futuro de las prótesis y la biónica, y la utilización de la nanotecnología en los implantes óseos antimicrobianos. En su tiempo libre, lee, pinta o construye sus propios ordenadores para jugar, y utiliza el poder de las redes sociales para compartir su pasión por la naturaleza con cientos de miles de personas.

C0095.indd XIII 16/07/21 10:56 AM

Propiedad de Elsevier
Prohibida su reproducción y venta

Biografías

Farhad Iranpour es cirujano traumatológico y ortopédico, y profesor clínico en el Imperial College London (Reino Unido). Está especializado en artroplastia, cirugía de rodilla y biomecánica musculoesquelética. Es un apasionado de la tecnología de vanguardia en materia de implantes y dispositivos médicos.

Glenn Cohen es titular de las Cátedras James A. Attwood y Leslie Williams de la Harvard Law School, y director docente del Petrie-Flom Center for Health Law Policy, Biotechnology, and Bioethics (Cambridge, Estados Unidos). Con más de 150 artículos y 15 libros, Cohen es uno de los principales expertos del mundo en la intersección entre la bioética y el derecho, así como en derecho sanitario.

Propiedad de Elsevier
Prohibida su reproducción y venta

Jakub P. Hlávka es profesor adjunto de Investigación de Políticas y Gestión Sanitarias, y miembro del Schaeffer Center for Health Policy and Economics de la University of Southern California (Los Ángeles, Estados Unidos). Trabaja en la intersección entre la medicina de precisión, la innovación en la asistencia sanitaria y el envejecimiento.

Johan Peter Bøtker es profesor adjunto del Departamento de Farmacia de la University of Copenhagen (Dinamarca), y trabaja en el campo de la tecnología y la ingeniería farmacéutica; específicamente en los sistemas de visión por ordenador. Utiliza herramientas de imagen y aprendizaje automático en varias aplicaciones farmacéuticas y de fabricación.

C0100.indd XV 16/07/21 10:48 AM

Justin Cobb es profesor y director del Departamento de Traumatología del Imperial College London (Reino Unido), donde dirige el MSk Lab, un grupo de 35 cirujanos, científicos e ingenieros. Es asesor en Stanmore Implants, una empresa subsidiaria de UCL. Es asesor civil en traumatología de la Royal Air Force y es cirujano ortopédico de su majestad la reina.

Khanhvi Tran es directora técnica de Sonohaler, una empresa centrada en el tratamiento predictivo del asma. Es licenciada en Ciencias Farmacéuticas y está especializada en métodos computacionales y desarrollo de *software*. Le apasiona el avance de la tecnología sanitaria.

Rajeev Dutt es un veterano con veinte años de experiencia en la industria de la alta tecnología, y ha ocupado cargos importantes en empresas como Hewlett Packard, Compaq, Microsoft, Intel y la BBC. Tiene experiencia en computación en la nube, inteligencia artificial, diseño de núcleos de sistemas operativos, sistemas de medios de comunicación y *hardware,* y tiene un título en Física Teórica del Trinity College de la University of Toronto (Canadá).

Reza Mirnezami es especialista en cirugía colorrectal en el Royal Free Hospital NHS Foundation Trust (Londres, Reino Unido). Su trabajo se centra principalmente en el cáncer colorrectal y dirige un programa de investigación cuyo objetivo es aplicar métodos de medicina de precisión al tratamiento de los pacientes con cáncer de colon.

Propiedad de Elsevier
Prohibida su reproducción y venta

Sara Gerke es investigadora en medicina, inteligencia artificial y derecho en el Petrie-Flom Center for Health Law Policy, Biotechnology, and Bioethics de la Harvard Law School (Cambridge, Estados Unidos), donde supervisa el trabajo diario del Project on Precision Medicine, Artificial Intelligence, and the Law (PMAIL) y dirige la investigación sobre derecho, políticas y ética. Sus investigaciones se centran en los desafíos éticos y legales de la inteligencia artificial y los datos masivos en Estados Unidos y Europa, así como en otras áreas, como las técnicas de reemplazo mitocondrial y la investigación con células progenitoras.

Stefano Colombo es un científico independiente que trabaja en la formulación farmacéutica y el desarrollo de productos biológicos de calidad por diseño. Es licenciado en Bioinformática por la Università degli Studi di Milano (Italia) y doctor en Administración de Fármacos por la University of Copenhagen (Dinamarca).

Propiedad de Elsevier
Prohibida su reproducción y venta

Timo Minssen es catedrático de Derecho y director fundador del Center for Advanced Studies in Biomedical Innovation Law (CeBIL) de la University of Copenhagen (Dinamarca). Su investigación y su práctica de asesoramiento a tiempo parcial se centran en la propiedad intelectual, la competencia y el derecho del registro sanitario, con especial atención a las tecnologías emergentes en ciencias de la salud y la vida, como la inteligencia artificial y la modificación génica.

Thomas Ward es investigador de inteligencia artificial e innovación en el Laboratorio de Inteligencia Artificial Quirúrgica e Innovación del Massachusetts General Hospital (Boston, Estados Unidos). Su investigación actual incluye la aplicación de la inteligencia artificial y la visión por ordenador al análisis de los vídeos intraoperatorios.

Zineb Jeddi es investigadora en ciencia de datos en la International University of Rabat (UIR, Marruecos). Se licenció en el National Institute of Statistics and Applied Economics (INSEA, Marruecos) y es ingeniera de investigación operativa y toma de decisiones.

Elan Witkowski es especialista en cirugía mínimamente invasiva del Massachusetts General Hospital e instructor de cirugía de la Harvard Medical School (Boston, Estados Unidos). Sus intereses clínicos incluyen la cirugía bariátrica y metabólica, y realiza cirugía abierta, laparoscópica y robótica. Sus intereses de investigación incluyen la epidemiología, los resultados quirúrgicos y la inteligencia artificial.

Arash Aframian es especialista en traumatología y cirugía ortopédica en el Imperial College Healthcare NHS Trust y el Chelsea and Westminster Hospital NHS Foundation Trust (Londres, Reino Unido), y le encanta su trabajo. Aplica su experiencia en tecnología de la información para desarrollar métodos de vanguardia en la asistencia sanitaria, y disfruta colaborando con sus compañeros para seguir expandiendo los límites de la tecnología sanitaria digital y los datos masivos.

Henrik Bohr es físico y actualmente es investigador en el Institute for Chemical Engineering de la Technical University of Denmark (Lyngby, Dinamarca). Su investigación se centra en la biofísica, el cálculo de la estructura biomolecular, y la física nuclear y molecular. Ha publicado más de 200 artículos científicos, incluidas unas 50 comunicaciones para reuniones científicas, en revistas internacionales en las áreas de la física teórica, la biofísica y la biotecnología.

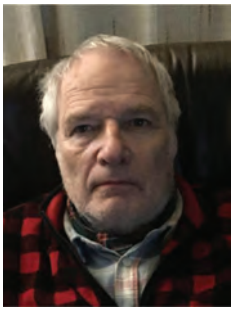

Propiedad de Elsevier
Prohibida su reproducción y venta

Prólogo

Sobre este libro

Hoy en día, casi todas las especialidades sanitarias han aceptado la inteligencia artificial (IA) como una herramienta viable que puede aportar un beneficio general a la sociedad. Esta herramienta se ha vuelto a poner de moda, pero esta vez se ha abierto camino realmente en todos los rincones de la investigación y el desarrollo, con numerosas publicaciones sobre datos masivos, aprendizaje automático y redes neuronales, así como algunas sobre sus aplicaciones para la asistencia sanitaria. A menudo, estas publicaciones son muy técnicas y están centradas en la investigación. En este libro, nuestro objetivo es abordar las principales aplicaciones de la IA en la asistencia sanitaria con una perspectiva fácil de entender y basada en pruebas, así como abordar los temas socioeconómicos fundamentales relacionados. Este libro trata temas que afectan a todo el ecosistema de la asistencia sanitaria, desde el diseño de medicamentos, las pruebas de imagen en medicina y la cirugía, hasta la privacidad de datos, los aspectos legales y la ética.

Propiedad de Elsevier
Prohibida su reproducción y venta

A quién se dirige

Este libro está escrito para un público amplio y específicamente para las personas interesadas en las aplicaciones sanitarias de la IA, como los médicos, otros profesionales de las ciencias de la salud y de la vida, los responsables políticos, los líderes empresariales, los estudiantes universitarios y los pacientes.

Cómo está organizado

Este libro tiene dos capítulos introductorios y diez capítulos temáticos sobre las aplicaciones y otras consideraciones de la IA en la asistencia sanitaria. Los primeros dos capítulos presentan el panorama actual en la asistencia sanitaria y el auge de la IA en este ámbito. Además, se describen las diferentes aplicaciones de la IA en la asistencia sanitaria. Los diez capítulos temáticos están escritos por especialistas en cada uno de los campos y abordan todo el ecosistema de la asistencia sanitaria. Todos estos capítulos pueden leerse como capítulos independientes y abordan los actuales avances de la IA en ese campo, a la vez que presentan estudios de casos específicos, ya que en esta publicación no se pueden abordar todas las tecnologías. En primer lugar, se presentan las aplicaciones de IA para el diseño y el desarrollo de fármacos, seguidas por sus aplicaciones en los

C0105.indd XIX 16/07/21 11:21 AM

campos del diagnóstico, el tratamiento y las pruebas de imagen médicas en oncología. A continuación, se tratan las aplicaciones de la IA en los dispositivos médicos y la cirugía, así como en la monitorización a distancia de los pacientes. Finalmente, el libro aborda los temas de la seguridad, la privacidad, el intercambio de información, los seguros de salud y los aspectos legales de la IA en la asistencia sanitaria.

Adam Bohr
Kaveh Memarzadeh

Propiedad de Elsevier
Prohibida su reproducción y venta

Introducción

Vivimos en un mundo matemático, y nuestro universo se rige por las leyes fundamentales de la física. A partir de este sistema matemático, y a lo largo de millones de años de selección natural, los seres vivos han evolucionado en el planeta Tierra. La forma en que se llegó a constituir este intrincado sistema, con todas sus complejidades, sigue siendo un misterio científico y filosófico. Hasta hace relativamente poco tiempo, los seres humanos asumían que el *Homo sapiens* era la especie más inteligente y capaz del planeta, supuestamente porque podemos llevar a cabo ciertas tareas mucho mejor que los demás terrícolas. Estas facetas o habilidades centrales, que supuestamente nos diferenciaban del resto de la vida, incluyen la resolución de problemas, el aprendizaje rápido y a partir de la experiencia, el razonamiento y la comprensión de ideas complejas. Por supuesto, es evidente que, mientras que la cuestión de la conciencia sigue siendo un misterio para la ciencia, ser inteligente no es exclusivo de los seres humanos. De hecho, si nos centramos de forma independiente en todos los aspectos centrales que se han señalado más arriba, es posible que otras especies puedan superar a los seres humanos. Sin embargo, los seres humanos son fantásticos generalistas y bastante imaginativos. Hacemos preguntas fundamentales sobre la naturaleza de la propia existencia y podemos proyectar pensamientos hacia el futuro con una mayor capacidad cognitiva, que es ligeramente diferente a la de los chimpancés. Esto nos permite soñar, contemplar y dar forma a nuestra realidad y mundo construyendo materiales y tecnología que hacen que la vida sea más fácil y manejable. Con esta increíble capacidad de imaginar cosas que nunca fueron, nosotros, como especie, hemos transformado el mundo que nos rodea.

Propiedad de Elsevier
Prohibida su reproducción y venta

Durante milenios, los seres humanos modernos han observado el vuelo de las aves en el cielo y se han preguntado por la conquista de los cielos; después de una multitud de intentos y fracasos, actualmente tenemos máquinas voladoras seguras que trasladan a cientos de personas de Estados Unidos a Asia Central en cuestión de horas. La inspiración clave aquí fue el acto de «volar». Para hacer dispositivos eficientes que pudieran transportar a cientos de personas en el aire no fue necesario imitar la forma exacta de «volar», sino comprender que es posible «volar», y que tal vez es posible hacerlo mejor y de una forma más eficiente que las aves. En una conversación con Lex Friedman, el neurocientífico Jeff Hawkins sugirió que para que los seres humanos entiendan lo que es la inteligencia, tenemos que entender cómo funciona el cerebro (principalmente la neocorteza), y que esto ya existe como marco complejo, por lo que solo se necesita más tiempo y esfuerzo. Esto es en lo que los pioneros de la inteligencia artificial (IA) han trabajado durante

C0110.indd XXI 16/07/21 11:18 AM

Figura 1 Mediante el uso de la capacidad del cerebro, los seres humanos pueden entender cómo se realizan ciertas tareas (mentales y físicas); la comprensión de los mecanismos subyacentes a estas tareas puede constituir la base de futuros algoritmos basados en la IA.

Propiedad de Elsevier
Prohibida su reproducción y venta

años. El objetivo sería inspirarse en los fenómenos de la «inteligencia» y no en el desarrollo de un sistema que tenga un aspecto y un funcionamiento iguales a los del cerebro humano (fig. 1).

La promesa de una máquina inteligente

El alunizaje fue una de las mayores hazañas de la humanidad. Este acontecimiento tuvo lugar hace más de medio siglo y no hace falta decir que el ordenador del proyecto Apolo 11 (ordenador guía Apolo) tenía la tecnología más avanzada de la época. Sin embargo, cuando se compara con la potencia de cálculo y procesamiento de los ordenadores actuales, e incluso de algunos de los teléfonos inteligentes más baratos, el ordenador guía Apolo parece una tecnología antigua. Este aumento en la velocidad de innovación, tanto en el *hardware* como en el *software,* ha hecho que haya más espacio para las actividades creativas, lo que ha permitido avanzar en la memoria, la potencia de procesamiento y el almacenamiento de los ordenadores, lo que a su vez ha llevado a la generación de grandes cantidades de datos.

Mientras que los seres humanos son cognitivamente competentes en el almacenamiento y la memorización de información, también son muy buenos en el olvido y, en la mayor parte de los casos, extremadamente buenos en el registro de ideas, pensamientos y datos en un sustrato externo y no en nuestro cerebro. Desde los antiguos egipcios hasta los griegos, la humanidad ha registrado diversos aspectos de sus vidas y fantasías en materiales inanima-

dos para la contabilidad, la cultura, la historia y la ciencia. Las palabras impresas y las medidas cuantitativas quedaron inmortalizadas con la introducción de la escritura alrededor del 3500 a. C. por los antiguos persas y mesopotámicos, que nos llevaron directamente a donde estamos hoy; de hecho, hace no menos de 100 años, los computadores que hacían cálculos cuantitativos eran seres humanos, como su nombre indica (los que computan). Sin embargo, es importante señalar que el coste de los errores en la computación (por seres humanos) para trabajos muy sensibles, así como también el tiempo perdido en corregir los errores innecesarios, parecía un ejercicio laborioso y consumía mucho tiempo, y este es un sello distintivo del pensamiento humano: somos falibles.

El famoso matemático, lógico y criptoanalista inglés Alan Turing entendió sumamente bien esta falibilidad y, en parte de su famoso artículo titulado «Computing Machinery and Intelligence» (Maquinaria para computación e inteligencia), destaca una situación imaginaria en la que un ser humano y una máquina participan en una sesión de preguntas y respuestas. En un momento dado, el humano le pide a la máquina que sume 34.957 y 70.764. Aquí, la máquina hace una pausa de unos 30 segundos (aparentemente calculando) y proporciona una respuesta de 105.621. La respuesta correcta es 105.721, por supuesto. En esta situación, el ser humano no sabe si el oponente es un humano o una máquina, y solo puede deducir esta incógnita basándose en sus respuestas. Parece que con este ejemplo Turing intentaba comunicar que los seres humanos a menudo relacionan los errores con otros seres humanos y esperan que una máquina siempre tenga razón. La respuesta incorrecta era entonces un truco de programación para engañar al ser humano haciéndole creer que se estaba comunicando con otro ser humano, y no con una máquina. Turing describió además la producción de una máquina que, de alguna manera, se inspira en el cuerpo humano, comentando que, «aunque este método probablemente sea una forma segura de producir una máquina pensante, parece ser demasiado lento o impracticable». En un giro irónico de los acontecimientos, dirige después su atención al cerebro y sugiere que tal vez podamos proporcionar y encontrar «ramas de pensamiento adecuadas para que la máquina ejerza sus poderes», teniendo al cerebro como inspiración, y propone varios campos de aplicación, como los juegos, el aprendizaje y la traducción de idiomas, la criptografía y las matemáticas.

Turing estuvo muy acertado en esta predicción. Históricamente, el campo de la inteligencia automática y la IA, como la mayoría lo llama, está enraizado en la forma en la que el sistema nervioso funciona a un nivel básico.

La puesta en práctica de todas las inspiraciones y descubrimientos de nuestro sistema nervioso, y especialmente el funcionamiento de nuestro cerebro, puede conducir, y de hecho conducirá, a diversos avances para el progreso de la humanidad. También es importante señalar que la creación de diversos algoritmos será un problema de ingeniería con un objetivo determinado, y no debería suponer la adopción exacta de la función biológica

Propiedad de Elsevier
Prohibida su reproducción y venta

del cerebro, aunque, por supuesto, hay investigadores que tal vez intenten imitar la función exacta del cerebro; sin embargo, consideramos que este abordaje es bastante innecesario y alentamos a las mentes creativas a encontrar inspiración en las funciones biológicas del cerebro y a utilizarlas como medio para encontrar formas novedosas de hacer frente a los desafíos actuales de la asistencia sanitaria. Proponemos que, debido a la interrelación y a la influencia circular de estas dos ramas de estudio, la IA por sí sola tendrá profundas consecuencias positivas en la salud humana en general, y no solo en el campo de la neurociencia.

Aplicaciones y desafíos actuales en la asistencia sanitaria

La prevención de las enfermedades debería desempeñar un papel importante en la asistencia sanitaria. Esto solo puede suceder si se permite que la sociedad acceda a una tecnología que pueda ofrecer a todos información precisa sobre el estado de su salud y su bienestar. Aunque los dispositivos inteligentes y los «ponibles» tienen múltiples aplicaciones, actualmente son tan solo algunas de las diversas herramientas utilizadas por las personas para controlar sus constantes vitales. La persona puede ver los datos analizados (que a menudo se presentan en una aplicación para dispositivos móviles o un sistema basado en la web), o los puede supervisar a distancia un profesional sanitario, lo que permite que el paciente aplique los cambios necesarios antes de que se produzca una enfermedad que ponga en peligro su vida.

Propiedad de Elsevier
Prohibida su reproducción y venta

Además, los pacientes que reciban asistencia clínica también tendrán más posibilidades de beneficiarse de un sistema cada vez más integrado. Los profesionales sanitarios que atienden a estos pacientes pueden tener acceso inmediato a los síntomas que refieran, a cualquier prueba de imagen, previa y futura, y a los análisis de biomarcadores, así como a sus tratamientos actuales. Esta integración de múltiples tipos de datos puede facilitar el flujo de trabajo y los procesos de toma de decisiones, pero, lo más importante es que estos procedimientos integrados también pueden permitir que los pacientes se beneficien de otras intervenciones que de otro modo se habrían pasado por alto o serían difíciles de aplicar. Además, para hacer frente a las enfermedades complicadas, debe disponerse de múltiples «vías de tratamiento». Se ha formulado la hipótesis de que el diseño y las combinaciones de fármacos eficaces que actúan sobre vías moleculares específicas podrían beneficiarse del campo del aprendizaje automático. Por ejemplo, se podría analizar individualmente a los pacientes con cáncer y elaborar una nueva vía «personalizada» para determinar qué fármaco o fármacos y qué combinaciones pueden utilizarse para un resultado óptimo del tratamiento. Estos avances en la asistencia sanitaria son, en su mayor parte, beneficiosos y mejorarán la longevidad y la prosperidad de la humanidad.

Por último, como este libro se centrará en la función y las aplicaciones de la IA en la asistencia sanitaria, es esencial recordar que, como la mayoría de los algoritmos utilizados hoy en día, en los siguientes capítulos los ejemplos de IA aplicada se denominan a menudo IA estrecha. Este término se refiere a un sistema que solo puede realizar una tarea o un pequeño conjunto de tareas relacionadas, y entrenarse para ellas. Desde el análisis de imágenes médicas hasta el aprendizaje del habla humana, la aplicación efectiva de la IA estrecha ha dominado el sistema sanitario y no debe confundirse con la inteligencia a nivel humano o la IA general, que puede realizar múltiples tareas complejas al mismo tiempo.

A pesar de esta aparente limitación, es probable que las operaciones realizadas con IA estrecha sean altamente competentes y eficientes en la realización de tareas humanas rutinarias y, en muchos casos, pueden superar a los seres humanos, lo que deja mucho tiempo para que los profesionales sanitarios se dediquen a tareas más productivas.

Adam Bohr
Kaveh Memarzadeh

Propiedad de Elsevier
Prohibida su reproducción y venta

Propiedad de Elsevier
Prohibida su reproducción y venta

CAPÍTULO 6

Inteligencia artificial para la imagen médica

Khanhvi Tran[1], Johan Peter Bøtker[2], Arash Aframian[3] y Kaveh Memarzadeh[4,*]
[1]Sonohaler, Copenhagen, Denmark
[2]Department of Pharmacy, University of Copenhagen, Copenhagen, Denmark
[3]NHS, London, United Kingdom
[4]ChemoMetec, Lillerød, Denmark

6.1 Introducción

Una imagen puede definirse como una función bidimensional *f(x, y)* donde *x* e *y* representan las coordenadas espaciales y la función *(f)* representa la amplitud en cualquier par dado de coordenadas *(x, y)*. La amplitud *(f)* también se suele denominar nivel de gris o intensidad de ese punto de la imagen. Por tanto, una imagen digital se compone de un número finito de estos elementos *x, y,* donde todos ellos tienen una ubicación y un valor exactos. Estos elementos de la imagen a menudo se denominan píxeles. De forma similar, las imágenes 3D pueden definirse mediante una función tridimensional *(x, y, z)* y los elementos individuales se denominan a menudo vóxeles. La calidad de la imagen es un parámetro importante en el campo de la radiología, y el término resolución espacial se refiere a la capacidad de diferenciar dos objetos vecinos en la imagen. Otra propiedad de resolución importante es la resolución temporal, que se refiere a la calidad de la imagen con respecto al tiempo.

El DICOM *(Digital Imaging and Communications in Medicine)* es el protocolo estándar para administrar y comunicar la información de imágenes médicas y los datos relacionados. DICOM es una marca registrada de la National Electrical Manufacturers Association. El estándar se usa ampliamente en radiología, cardiología, oncología, obstetricia y odontología. Los archivos DICOM transmiten imágenes e información a sistemas capaces de recibir datos e imágenes del paciente en formato DICOM. Un archivo DICOM consta del sitio de origen, la identificación del paciente, la imagen en sí y los atributos de la imagen, como el tamaño de píxel. Es importante destacar que los archivos DICOM garantizan que los datos del paciente y los datos de las imágenes no se puedan separar. En consecuencia, la imagen DICOM siempre está vinculada al paciente.

Propiedad de Elsevier
Prohibida su reproducción y venta

* Autor de correspondencia

© 2022. Elsevier España, S.L.U. Reservados todos los derechos

C0030.indd 143 15/07/21 7:08 PM

No hay consenso sobre dónde termina el procesamiento simple de imágenes y dónde comienza un análisis de imágenes y una visión por computadora más avanzados. En ocasiones se realiza una definición caracterizando el procesamiento de imágenes como una operación en la que tanto la entrada como la salida de una operación es una imagen. Esta es, quizá, una definición demasiado limitante, puesto que una tarea trivial de computación, por ejemplo, la intensidad media de una imagen no se consideraría entonces como una operación de procesamiento de imágenes. En el otro extremo de la escala existe la visión por computadora, donde el objetivo es emular la percepción humana y las acciones del dispositivo basadas en las entradas. La visión por computadora es una rama de la inteligencia artificial (IA), y la IA utiliza la inteligencia humana como inspiración. No existe una frontera entre el procesamiento de imágenes ordinario, la visión por computadora y la IA. Sin embargo, puede resultar útil caracterizar las operaciones ordinarias, como la reducción de ruido, la nitidez de la imagen y la mejora del contraste, como procesos de bajo nivel. Los procesos de nivel medio pueden involucrar la detección de objetos dentro de la imagen (segmentación de la imagen) y la clasificación posterior de esos objetos. Los procesos de alto nivel pueden involucrar un conjunto de objetos clasificados donde las conclusiones se pueden comparar con lo que se obtendría mediante una evaluación humana.

Propiedad de Elsevier
Prohibida su reproducción y venta

6.2 Resultados de la inteligencia artificial en radiología/imágenes médicas

6.2.1 Preprocesamiento

Las operaciones de imagen, como la mejora de la imagen, la normalización de la imagen y la eliminación de ruido, se realizan a menudo en una etapa de preprocesamiento. La mejora de la imagen es un proceso en el que la imagen se ajusta para que sea más adecuada para la visualización o el análisis adicional. Los ejemplos específicos incluyen la eliminación del ruido de la imagen, la nitidez de la imagen, los ajustes de intensidad de la imagen o facilitar la detección de objetos (segmentación de la imagen). Existe una variedad de métodos para lograr tales objetivos.

El filtrado con operadores morfológicos se puede utilizar como método para eliminar objetos pequeños en la imagen y corregir la iluminación de fondo no uniforme. El filtrado se puede realizar utilizando un elemento estructurante de tamaño y forma personalizables. Un elemento de estructuración más grande eliminará objetos más grandes que un elemento de estructuración más pequeño. En el caso de corregir la iluminación de fondo no uniforme, se eliminan todos los objetos de la imagen y la intensidad del fondo se puede evaluar y restar posteriormente de la imagen original. El filtrado de mediana se puede utilizar, por ejemplo, para eliminar el ruido en las

imágenes. El método de filtrado de la mediana funciona asignando el valor del píxel de salida al valor de la mediana de los píxeles de entrada vecinos. Este enfoque elimina los valores atípicos en los valores de píxeles, ya que estarían lejos del valor mediano de los valores de píxeles vecinos.

La ecualización del histograma, también conocida como la normalización de la imagen, se puede utilizar para realizar ajustes de contraste en la imagen, de modo que los valores de intensidad de la imagen abarquen todo el rango de intensidad. Además, este intervalo más grande de los valores de intensidad permite diferencias más marcadas entre las regiones oscuras y brillantes.

En el campo de la adquisición de imágenes también es posible encontrar ruido periódico en las imágenes, que normalmente se origina a partir de interferencias eléctricas y/o electromecánicas que afectan a la adquisición de imágenes. Para eliminar el ruido periódico es necesario determinar sus parámetros. Por lo general, se evalúa analizando el espectro de Fourier de la imagen. Este ruido periódico produce picos de frecuencia que se pueden detectar fácilmente y, cuando son lo suficientemente pronunciados, se puede utilizar un análisis automatizado para aliviar la carga de determinar los parámetros de entrada.

Propiedad de Elsevier
Prohibida su reproducción y venta

6.2.2 Segmentación

La segmentación de imágenes es un paso importante en muchas áreas del campo de las imágenes médicas. Este se puede caracterizar como un proceso en el que los objetos o regiones de interés se subdividen dentro de la imagen. Por tanto, la subdivisión o segmentación debería detenerse cuando se haya aislado la región de interés o el objeto. La segmentación de imágenes es una de las tareas más exigentes y su precisión es fundamental para posteriores fallos o aciertos de análisis.

A menudo, los algoritmos de segmentación se basan en similitudes de valor de la intensidad de la imagen o en discontinuidades del valor de la intensidad de la imagen. En el primer caso, la segmentación se basa en subdividir la imagen en objetos o regiones de interés que parecen tener valores de intensidad similares, según un conjunto de criterios predefinidos. En el segundo caso, la segmentación se basa en subdividir la imagen siguiendo cambios abruptos en las intensidades. Dentro de la segmentación de imágenes usando discontinuidades de intensidad existen tres tipos básicos de enfoque: detección de puntos, líneas y bordes. Con respecto a la detección de puntos y líneas, estas técnicas implican la detección, respectivamente, de puntos aislados o líneas rectas en una imagen dada y, por supuesto, son importantes en la segmentación de imágenes en general. Sin embargo, la detección de bordes es de largo el método más utilizado para detectar discontinuidades en los valores de intensidad. Esto se debe a que un borde, en este caso, puede describirse como una línea curvada arbitrariamente y, especialmente en las imágenes médicas, a menudo no estamos interesados en detectar puntos o

© Elsevier. Fotocopiar sin autorización es un delito.

líneas rectas. Para la detección de bordes se utilizan las primeras derivadas, ya que tienen propiedades que requieren que sean cero en regiones de la imagen con intensidad constante, y distintas de cero y que estén correlacionadas numéricamente con el grado de cambio de intensidad en regiones con intensidades variables.

Para la segmentación de imágenes usando similitudes de valores de intensidad, a menudo se usa el umbral. Los umbrales básicos disfrutan de un uso generalizado debido a su simplicidad de implementación y a sus propiedades intuitivas. En la configuración más básica se puede determinar un valor de umbral mediante prueba y error y, posteriormente, terminar con un valor que se ajuste al propósito según lo juzgue el usuario. Alternativamente, se puede evaluar un valor umbral mediante la inspección visual de un histograma de la imagen. Por supuesto, estos dos métodos propuestos dependen en gran medida del usuario, por lo que suele ser aconsejable utilizar un algoritmo que elija automáticamente un valor de umbral en función de los datos de imagen en cuestión.

6.2.3 Detección de objetos

La detección de objetos mediante cuadros delimitadores se utiliza a menudo junto con algoritmos de redes neuronales de aprendizaje profundo y se ha implementado en imágenes médicas para detectar estructuras anatómicas en tomografías computarizadas (TC) [1]. Esta técnica se suele utilizar para identificar una o varias regiones de interés en una imagen. Podría utilizarse para la detección automática de cálculos biliares en pacientes y, al mismo tiempo, localizar la posición del hígado y la columna en la imagen (fig. 6.1) [2].

Propiedad de Elsevier
Prohibida su reproducción y venta

6.3 Usar la inteligencia artificial en radiología y superar sus obstáculos

Con la disponibilidad actual de *big data,* una mayor potencia informática y nuevos algoritmos, muchos desafíos se han vuelto manejables. Sin embargo, todavía existen obstáculos al utilizar la IA en radiología. Uno de los mayores obstáculos es la necesidad de una gran cantidad de conjuntos de datos etiquetados de alta calidad que tengan un modelo de entrenamiento satisfactorio, un conjunto de datos equilibrado que sea representativo de todos los datos. En comparación con las bases de datos generales, el volumen de conjuntos de datos de imágenes médicas sigue siendo inmensamente escaso, con solo cientos o miles de imágenes por conjunto de datos, en comparación con millones de imágenes, por ejemplo, en ImageNet [3,4]. La cantidad de datos de pacientes con la misma enfermedad es escasa, más aún en el caso de las enfermedades raras, y los datos etiquetados de alta calidad de los expertos son limitados y costosos [5-7]. En consecuencia, se entrena un modelo no ajustado o, a menudo, sobreajustado, y este clasifica incorrectamente o no

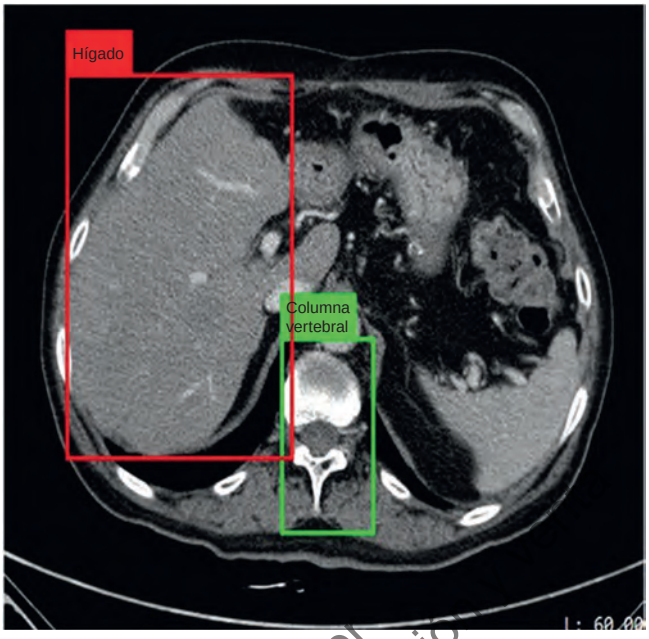

Figura 6.1 Una muestra negativa correctamente reconocida. *Reproducido de Pang S, et al. A novel YOLOv3-arch model for identifying cholelithiasis and classifying gallstones on CT images. PLoS One 2019;14(6):e0217647. doi:10.1371/journal.pone.0217647.*

Propiedad de Elsevier
Prohibida su reproducción

detecta la información crítica. En radiología es especialmente importante evitar los resultados falsos negativos, ya que pueden tener repercusiones graves para el paciente y el médico, por ejemplo, si el modelo no detecta una lesión benigna [6,8].

Cuando los modelos tienen muchos parámetros y no hay suficientes datos de entrenamiento para equilibrar, surge el problema del sobreajuste. Para compensar la falta de datos de entrenamiento o simplemente de datos etiquetados limitados, se pueden aplicar diferentes métodos. En algunos casos, los conjuntos de datos con menos de 100 pacientes han arrojado un rendimiento adecuado [6]. A continuación nos centraremos en cómo expandir el conjunto de entrenamiento al transformar los datos actuales, generar datos sintéticos, regularizar el modelo y aprovechar los conjuntos de datos etiquetados externos.

6.3.1 No hay suficientes datos de entrenamiento (aumento de datos)

En el aumento de datos tradicional, la estructura espacial, la apariencia y la calidad de las imágenes se manipulan, pero conservan las etiquetas para convertirse en nuevas imágenes que, a su vez, amplían el conjunto de datos.

© Elsevier. Fotocopiar sin autorización es un delito.

- Las transformaciones *espaciales* alteran la imagen mediante rotación, volteos, escalado y deformación, que imitan diferentes orientaciones durante el escaneo, variabilidad de formas y movimiento en el tejido.
- El aumento basado en la *apariencia* transforma las características estadísticas, como el brillo y el contraste en las intensidades de la imagen, imitando diferentes protocolos de escaneo y proveedores de dispositivos.
- La *calidad de la imagen* se manipula mediante la borrosidad, la nitidez y el nivel de ruido. Los dos primeros son uno el inverso del otro y son comúnmente causados por artefactos de movimiento y la resolución de la RM/ultrasonido.

Las imágenes de los aumentos tradicionales pueden estar altamente correlacionadas, tener un enfoque insuficiente en condiciones raras y, por tanto, tener un impacto limitante. También es computacionalmente costoso en grandes conjuntos de datos 3D [9,10].

El aumento sintético de datos se puede categorizar en síntesis de imágenes del mismo dominio y entre dominios, generando datos etiquetados en el dominio objetivo o transfiriendo datos etiquetados desde un dominio diferente al dominio objetivo, respectivamente.

La última categoría es similar a la adaptación de dominio y se aborda en detalle más adelante. Se proponen varios métodos para generar imágenes sintéticas con las características del conjunto de datos dado mediante el uso de una clase de redes neuronales denominadas redes generativas adversarias (RGA); estos son modelos generativos que crean nuevos datos. Utilizando las RGA, se pueden generar versiones alternativas o características de las imágenes para ampliar el conjunto de datos para un entrenamiento adicional [10,11].

Propiedad de Elsevier
Prohibida su reproducción y venta

6.3.2 Datos de entrenamiento desequilibrados (ponderación de datos)

Para combatir el sobreajuste se pueden utilizar métodos de regularización. Este es el medio por el que los pesos entre dos capas de conexión se ajustan a un rango más efectivo. El método tradicional es la regularización de pesos. Los pesos del modelo se mantienen pequeños para hacerlo más simple y robusto. Un método alternativo es el método de abandono, donde los pesos se establecen aleatoriamente en cero. Los resultados mostrarán claramente qué ponderaciones afectan al rendimiento y, después de suficientes iteraciones, solo se mantienen las ponderaciones importantes [8,10,12].

6.3.3 Datos de entrenamiento no representativos (aprendizaje de transferencia, adaptación de dominio)

Además de requerir una gran cantidad de datos, los datos de entrenamiento deben ser representativos del modelo que «conocerá» en el futuro; de lo contrario, es posible que el modelo no se generalice a los nuevos datos. En

consecuencia, un modelo entrenado con datos de uno o más hospitales puede tener un peor rendimiento con datos de otros hospitales diferentes. Para aumentar la capacidad de generalización de un modelo, el algoritmo de aprendizaje debe incluir un sesgo inductivo, un conjunto de suposiciones sobre la verdadera distribución de datos para predecir los resultados de la entrada que aún no ha visto. Para lograr esto, el modelo puede entrenarse con todos los datos disponibles, lo que es muy ineficiente, o puede transferir «conocimiento» de un abundante conjunto de datos al modelo actual para generar datos más representativos [13-15].

6.3.3.1 Aprendizaje por transferencia

Los seres humanos pueden abstraer el conocimiento de un dominio de origen y aplicar el conocimiento para aprender un nuevo dominio de destino. En comparación con una persona sin experiencia musical, un guitarrista puede transferir su conocimiento musical previamente aprendido (dominio de origen) para aprender de manera más rápida y eficaz la tarea de tocar el piano (dominio de destino). Del mismo modo, un modelo que puede clasificar imágenes de ImageNet probablemente funcione mejor en un conjunto de datos de imágenes médicas, en contraposición a un modelo con pesos aleatorios [16]. En el aprendizaje por transferencia, también llamado «ajuste fino» o «preentrenamiento», los pesos de una red previamente entrenada con abundancia de datos (generalmente ImageNet para imágenes 2D) se ajustan para adaptarse a un nuevo dominio objetivo (fig. 6.2).

El aprendizaje de transferencia permite la transferencia de conocimiento entre dominios, tareas o distribuciones y se agrupa de acuerdo con lo que se transfiere (transferencia de instancia, transferencia de representación de características, transferencia de parámetros, transferencia de conocimiento relacional) y dónde tiene lugar la transferencia [15,17,18]:

Propiedad de Elsevier
Prohibida su reproducción y venta

Figura 6.2 Una descripción del flujo del aprendizaje por transferencia (inspirada en el aprendizaje por transferencia explicado por integrate.ai).

© Elsevier. Fotocopiar sin autorización es un delito.

- *Inductivo:* diferentes tareas se transfieren a través del mismo dominio. El dominio de origen se utiliza para mejorar el dominio de destino al aprovechar el conocimiento de la tarea de origen para elegir o ajustar el sesgo inductivo de la tarea de destino. Si el dominio de origen contiene datos etiquetados, las tareas de origen y destino se aprenden simultáneamente y se denomina aprendizaje multitarea, mientras que si no hay datos etiquetados disponibles utilizan el autoaprendizaje.
- *No supervisado:* las tareas son diferentes, los dominios son similares, pero no hay datos etiquetados disponibles.
- *Transductivo:* las tareas son similares y los dominios son diferentes. Por lo general, el dominio de origen contiene una gran colección de datos etiquetados, mientras que el dominio de destino no tiene ninguno. Esto también se conoce como adaptación de dominio.

6.3.3.2 Adaptación de dominio

Las imágenes entrenadas y evaluadas en el mismo dominio, es decir, el mismo protocolo, escáner de imágenes por resonancia magnética (IRM), resolución y contraste de imagen, tienen más probabilidades de enfrentar el problema del cambio de dominio cuando el modelo se usa en casos del mundo real: la distribución de datos solo representa los aprendizajes del conjunto de entrenamiento, lo que hace que el modelo sea menos generalizable [15,19].

La adaptación de dominio es una forma de aprendizaje por transferencia, donde la tarea del dominio de origen y destino es la misma (es decir, los dominios comparten etiquetas de clase), pero el dominio de origen y destino, la representación o la distribución de datos son diferentes.

Cuando las etiquetas solo están disponibles en el dominio de origen, las imágenes se traducen del dominio de origen al de destino. Esto se llama adaptación de dominio no supervisado (ADNS). Un ejemplo de ADNS es la traducción de imágenes de resonancia magnética que contienen máscaras del bazo en imágenes de TC de bazo para la tarea de segmentación del bazo [20]. Manteniendo la estructura anatómica, y con eso las máscaras de segmentación, las imágenes de origen se traducen a las características del dominio de destino. Las predicciones de las imágenes de destino se realizan mediante el uso de imágenes sintetizadas y máscaras de origen para entrenar una red de segmentación [10,13,21,22].

Si se etiqueta un pequeño conjunto de ejemplos objetivo, la adaptación de dominio se considera semisupervisada, mientras que, si ambos dominios contienen datos etiquetados, se clasifican como adaptación de dominio supervisada. En este caso se aprende una representación compartida entre los dos dominios para predecir las etiquetas de datos independientemente del dominio de entrada [10,21].

Propiedad de Elsevier
Prohibida su reproducción y venta

6.3.3.2.1 Caja negra: explicación del algoritmo

A medida que los nuevos algoritmos evolucionan para realizar estas predicciones, ¿cómo nos aseguramos de que sean precisas, cuando la red neuronal profunda es una caja negra? Por tanto, está surgiendo un nuevo campo para combatir este problema, llamado IA explicable, que busca aumentar la interpretabilidad, visualizar características y medir la sensibilidad por otros medios. Otra forma de aumentar la confiabilidad es calcular estimaciones de incertidumbre mientras se hacen predicciones, lo que se puede hacer con el aprendizaje profundo bayesiano [13,23].

6.3.3.2.2 Implementación/integración

La construcción de un algoritmo de predicción preciso solo puede llegar hasta cierto punto si el radiólogo no puede o no quiere usarlo, lo que cimenta otro punto de confiabilidad. El desarrollo de un sistema para uso clínico debe realizarse en colaboración con el usuario final para asegurarse de que todo el flujo de trabajo también funcione en un entorno práctico y genere confianza en los sistemas [5,13]. Los desarrolladores también deben tener en cuenta las preocupaciones sobre la privacidad y la construcción para un uso reglamentario, ético y legal [13,23,24].

Propiedad de Elsevier
Prohibida su reproducción y venta

6.4 Rayos X e inteligencia artificial en imágenes médicas: caso 1 (Zebra medical vision)

6.4.1 Los rayos X y su papel en la medicina

El descubrimiento de las imágenes de rayos X revolucionó el campo de la medicina. Este descubrimiento es una parte intrínseca de nuestra sociedad moderna, la fabricación, los aeropuertos y descubrimientos importantes como el ADN. Las imágenes de rayos X se descubrieron en el año 1896. Inicialmente, los rayos X se usaban con fines de entretenimiento y las personas usaban «estudios fotográficos de huesos» para adquirir una radiografía de sus manos, cabeza, piernas o pecho y usar estas imágenes como objetos de adorno para ser admirados por todos. Durante este periodo, los fluoroscopios portátiles (fig. 6.3) se inventaron para que las personas usaran un casco (muy parecido a los auriculares de realidad virtual de hoy en día), levantaran una mano frente a la pantalla y pudieran ver sus propios esqueletos. Por supuesto, ahora hay una buena razón para saber por qué estos dispositivos no son seguros de usar. Durante el mismo periodo, algunos científicos y médicos también identificaron el potencial de salvar vidas de esta tecnología, al darse cuenta de que las fracturas óseas podían visualizarse cuando se exponían a rayos X.

© Elsevier. Fotocopiar sin autorización es un delito.

Figura 6.3 Un fluoroscopio de mano, que es extrañamente similar a algunos de los auriculares de «realidad virtual» de hoy.

Propiedad de Elsevier
Prohibida su reproducción y venta

6.4.2 Descubrimiento de rayos X

El individuo responsable del descubrimiento de los rayos X fue un físico e ingeniero alemán llamado Wilhelm Conrad Roentgen. Roentgen fue profesor de física en la Universidad de Würzburg, Alemania. Cerca del momento de su descubrimiento, Roentgen estaba trabajando en un dispositivo denominado «tubo de Crookes», un tubo de descarga eléctrica experimental que se pensaba que producía diferentes tipos de rayos. El 8 de noviembre de 1895 Roentgen instaló su tubo de Crookes en su oficina para perseguir su objetivo de descubrir nuevos rayos «invisibles». Envolvió el tubo incandescente en un papel negro para evitar su brillo visible y, con las luces apagadas en la habitación, Roentgen notó un resplandor verde brillante en una pantalla fluorescente primitiva (un trozo de cartón con algunos cristales de platinocianuro de bario en él) que había encima de una mesa en la habitación. Le resultó curioso que el resplandor brillante en el cartón desapareciera cuando el experimento no estaba en funcionamiento. Roentgen no se detuvo allí. Experimentó además colocando varios materiales (incluida su propia mano) entre el cartón y el tubo y observó que algunos materiales como el papel no bloqueaban los rayos, pero los objetos metálicos y su propia mano trazaban un contorno en la pantalla fluorescente. Durante las siguientes semanas, Roentgen supuestamente refinó el método y llamó a los rayos recién descubiertos «X» debido a su naturaleza desconocida. Durante el mismo periodo, tomó la fotografía de la primera radiografía de la mano de su esposa que se puede ver en la figura 6.4.

Figura 6.4 La primera imagen de rayos X de una mano.

Propiedad de Elsevier
Prohibida su reproducción y venta

6.4.3 Radiografías de tórax

Poco después de su descubrimiento, y debido a su potencial único, los rayos X se utilizaban continuamente y hasta hace muy poco tiempo todas las imágenes eran manipuladas físicamente por profesionales sanitarios. Sin embargo, con los avances recientes en la tecnología informática, la mayoría de las imágenes de rayos X se digitalizan y, con millones de pacientes examinados a diario, la cantidad de datos producida es simplemente enorme.

Las radiografías de tórax son esenciales en el campo de la radiología porque con ellas se realizan varios diagnósticos que cambian la vida. Son baratas y se pueden realizar rápidamente, incluso en las regiones más subdesarrolladas del mundo. Sin embargo, a menudo hay una gran carga de trabajo asociada con las imágenes obtenidas. Su interpretación puede ser difícil y el error humano puede ser común debido a complejidades anatómicas, como las interfaces entre las lesiones y el hueso. Por tanto, se pueden implementar algoritmos basados en IA para ayudar y guiar a los expertos clínicos en su proceso de toma de decisiones. Además, la falta de expertos en radiología para fines de diagnóstico es una preocupación creciente. Solo en Reino Unido, entre 2012 y 2017, la demanda de car-

© Elsevier. Fotocopiar sin autorización es un delito.

ga de trabajo de los radiólogos ha aumentado un 30%, mientras que el porcentaje de médicos expertos ha aumentado solo un 15% [25]. Por tanto, la implementación de sistemas inteligentes puede traer beneficios significativos y mejorar la optimización del flujo de trabajo para médicos y trabajadores de la salud [26].

6.4.4 RadBot-CXR: hallazgos clínicos mediante el aprendizaje profundo

No se puede ignorar la influencia y el carácter innovador de las pequeñas empresas que están surgiendo cada vez más en el campo de la radiología. El mundo actual ofrece grandes campos de «terreno fértil» digital para que los empresarios e inventores entusiastas experimenten y jueguen con ideas. Aquí destacamos brevemente el logro de una empresa innovadora llamada Zebra MedicalVision (ZMV), una *start-up* de desarrollo *software* que está «empoderando a los radiólogos» con su revolucionaria IA y ayuda a los proveedores de salud a gestionar la carga de trabajo cada vez mayor sin comprometer la calidad. Según ZMV, esto se puede lograr utilizando cientos de miles de escaneos antiguos y nuevos para crear un *software* que analice datos presentes y futuros con precisión de nivel humano, brindando así a los profesionales la asistencia que necesitan.

Como ha señalado anteriormente, el análisis de imágenes y la radiología de diagnóstico tienen una gran demanda. Hoy en día, a menudo se solicita a otros médicos (no expertos) y técnicos radiográficos que proporcionen una interpretación preliminar de las imágenes a los pacientes. Esto se hace en un esfuerzo por disminuir el intervalo de espera para los pacientes, pero puede conducir a una reducción en la precisión del diagnóstico. Incluso entre los radiólogos expertos se cometen errores clínicos graves [27]. Por tanto, hay algunas decisiones diagnósticas bastante retadoras que deben tomarse y, debido a las largas horas de trabajo, la carga de trabajo y el volumen de exámenes, las afecciones como el cáncer de pulmón temprano a menudo se pasan por alto en el 19-54% de los casos [28] y se pueden cometer errores menores alrededor del 30% de las veces [29].

La escasez de experiencia para un análisis completo, preciso y rápido de imágenes ha llevado a ZMV a emplear redes neuronales convolucionales (RNC) para abordar el problema. RadBot-CXR se ha desarrollado y validado con un sistema de interpretación automática de nivel experto para la detección de cuatro categorías que se relacionan con siete hallazgos radiográficos distintos en la radiografía de tórax: consolidación alveolar, masa pulmonar, atelectasia, derrame pleural, prominencia hiliar, edema pulmonar difuso y cardiomegalia. Las cuatro categorías principales son la opacidad general, la cardiomegalia, la prominencia hiliar y el edema pulmonar, donde los informes del *software* verificarán la existencia o no existencia de cada una de estas categorías. Estas categorías brindan una

Propiedad de Elsevier
Prohibida su reproducción y venta

visión profunda del diagnóstico del paciente. Además, los datos obtenidos de esta RNC han demostrado que el nivel de acuerdo entre el sistema RadBot-CXR y los radiólogos es ligeramente superior al acuerdo interobservador entre un equipo de tres radiólogos expertos [30]. Además, estos resultados muestran una mejora significativa en el desempeño de los radiólogos después de conocer los resultados del algoritmo. ZMV afirma que la importancia de dicho *software* entra en juego cuando hay escasez de personal clínico experimentado y una gran demanda de diagnóstico de nivel experto.

6.4.5 Detección de la osteoporosis mediante inteligencia artificial

En los últimos años, la tecnología médica y las intervenciones eficaces han provocado el envejecimiento de la población. Esto significa que mientras vivimos más, somos cada vez más propensos a nuevos tipos de afecciones. Las afecciones musculoesqueléticas ocupan un lugar destacado en esta lista y se prevé que aumenten y, potencialmente, hagan crecer las tasas de mortalidad [31]. La osteoporosis es una afección común dentro de las afecciones musculoesqueléticas que conduce a una reducción de la masa ósea, lo que aumenta el riesgo de fractura ósea en los últimos años de vida [32]. Esta condición se agrava cuando afecta a las vértebras, dando lugar a fracturas vertebrales por compresión (FVC), fenómeno que conduce a un debilitamiento significativo de la columna vertebral y que a menudo se manifiesta en los ancianos con una característica espalda redondeada y un aspecto encorvado. A pesar de su naturaleza incapacitante y del hecho de que aumenta las posibilidades de una fractura de cadera más adelante, las medidas de diagnóstico convencionales para identificar esta afección mediante el uso de sistemas de imágenes como la TC han sido menos que satisfactorias.

Mediante la creación de un algoritmo robusto que puede detectar las FVC en radiografías obtenidas del tórax y el abdomen, los investigadores y el equipo de ZMV pudieron obtener imágenes de regiones de la columna vertebral. Estas regiones se clasificaron en binario, se juntaron y se entrenaron usando una RNC y luego se ejecutaron en redes neuronales recurrentes (RNR). Las RNR son una poderosa herramienta de aprendizaje profundo que a menudo se utilizan para modelar secuencias. Junto con las RNC, las RNR pueden predecir la probabilidad de presencia de FVC en las imágenes de la tomografía computarizada. ZMV afirma que las RNR entrenadas dieron como resultado una sensibilidad del 83,9%, una especificidad del 93,8% y una precisión del 89,1% [33].

Con resultados tan prometedores, el aprendizaje profundo está en camino de convertirse en una característica integral para el futuro del análisis de las imágenes médicas.

Propiedad de Elsevier
Prohibida su reproducción y venta

© Elsevier. Fotocopiar sin autorización es un delito.

6.5 Ultrasonidos e inteligencia artificial en imágenes médicas: caso 2 (Butterfly iQ)

6.5.1 Ultrasonidos y su papel en la medicina

El ultrasonido médico (ecografía) es una tecnología médica que utiliza ondas sonoras de alta frecuencia para permitir a sus usuarios observar eventos dentro del cuerpo humano. A menudo se utiliza un transductor para producir y dirigir ondas de sonido a la región de interés y los resultados habitualmente se observan en vivo en un monitor integrado.

Los usos de la ecografía con fines de diagnóstico suelen ser anatómicos o funcionales. El ultrasonido anatómico se suele usar para producir imágenes de estructuras individuales dentro del cuerpo, mientras que el ultrasonido funcional parte de esto y mide el movimiento y la velocidad de la sangre o la suavidad o dureza del tejido. Esto permite a los médicos ver cambios funcionales dentro de una estructura u órgano corporal. Esta tecnología ahora se usa ampliamente como terapia para tratar una variedad de condiciones médicas. Las ondas sonoras ultrasónicas de alta intensidad tienen la capacidad de modificar y destruir tejidos no deseados, como los tumores. Estas ondas sonoras también pueden, potencialmente, administrar medicamentos y también pueden alterar los coágulos de sangre no deseados que, de otra manera, podrían conducir a resultados catastróficos para la salud.

Debido a su diversidad, seguridad y coste relativamente bajo, la ecografía se utiliza cada vez más en la medicina diagnóstica y terapéutica (fig. 6.5).

Propiedad de Elsevier
Prohibida su reproducción y venta

6.5.2 El Butterfly iQ

El Butterfly iQ es un innovador dispositivo de ultrasonido de bolsillo, desarrollado por Butterfly Network. Utiliza partes basadas en transductores de ultrasonido capacitivos micromecanizados (TUCM) integrados en semiconductores de óxido metal complementario (SOMC) en la sonda ultrasónica. Se diferencia de todos los demás competidores al utilizar TUCM de chip de silicio en lugar de utilizar transductores basados en cristales piezoeléctricos convencionales. El TUCM tiene un ancho de banda mucho más amplio en comparación con los transductores piezoeléctricos, que están sintonizados para oscilar a frecuencias específicas. Por tanto, se puede utilizar un TUCM para detectar y emitir muchas frecuencias diferentes y, como resultado, se puede utilizar un TUCM para obtener imágenes de todo el cuerpo. Un área importante de aplicación futura para el Butterfly iQ es su interacción con la IA. La compañía ha anunciado que esta es una dirección que investigará alimentando un algoritmo de aprendizaje profundo con las imágenes cargadas de los usuarios. El objetivo de la IA es permitir que el *software* proporcione orientación al usuario tanto durante la interpretación de las imágenes como durante la adquisición de las imágenes. Dichas capacidades de IA podrían expandir drásticamente la aplicación del dispositivo a diferentes ámbitos de

Figura 6.5 Un dispositivo Butterfly iQ de mano. Dispositivos similares al iQ pueden revolucionar el campo de la medicina al permitir imágenes accesibles y fáciles de usar en cualquier lugar. *Reproducido con permiso de https://www.butterflynetwork.com/.*

Propiedad de Elsevier
Prohibida su reproducción y

uso. En un escenario, la empresa prevé que, en entornos de bajos recursos, las interpretaciones y la orientación guiadas por IA serán valiosas. En otro escenario, el bajo coste del dispositivo, combinado con las posibles capacidades guiadas por IA, puede implicar que se pueda ofrecer como un dispositivo médico personal [34].

Los algoritmos de aprendizaje profundo de la red Butterfly se utilizan para impulsar sus aplicaciones de visión por computadora. Al entrenarlos con suficientes imágenes relacionadas con una afección médica, su programa aprende cómo escanear las regiones correctas del cuerpo del paciente y puede distinguir el tejido normal del anormal. Actualmente, la mayor parte del procesamiento y análisis de imágenes se lleva a cabo en la nube y no en el dispositivo o las redes locales.

La facilidad de uso de dispositivos como el Butterfly iQ y el bajo coste de obtener cada imagen hace que sea atractivo y rápido recolectar una gran cantidad de imágenes para su análisis. Se prevé que este dispositivo esté disponible en los minoristas, incluidas las farmacias o en las clínicas, y que las imágenes capturadas con el dispositivo se puedan enviar a un médico para un análisis más detallado, similar a las aplicaciones de telemedicina.

La naturaleza conectada y automatizada del dispositivo también permitiría entregar un diagnóstico casi instantáneamente, en lugar de semanas de retraso y espera.

© Elsevier. Fotocopiar sin autorización es un delito.

6.6 Aplicación de la inteligencia artificial en imágenes médicas: caso 3 (Arterys)

Las enfermedades cardiovasculares son enfermedades que abarcan tanto el corazón como los vasos sanguíneos. Por tanto, un factor importante, que a menudo se pasa por alto, es el flujo sanguíneo. Además, las mediciones relevantes se realizan manualmente, lo que requiere mucho tiempo y se realiza con poca automatización.

Los fundadores de Arterys, la primera plataforma de imágenes médicas con la aprobación de la FDA para el uso de IA en un entorno clínico, combina aprendizaje profundo, flujo 4D (una técnica que permite el examen directo del flujo y la función del corazón mediante resonancia magnética) y computación en la nube para ayudar a los radiólogos en su trabajo diario [35] (fig. 6.6).

En un solo escaneo corto, en comparación con un escaneo convencional, el flujo 4D adquiere información volumétrica anatómica, funcional y de flujo durante todo el ciclo cardíaco. Esto sucede mientras el modelo de aprendizaje profundo clasifica y segmenta el corazón, con tanta precisión

Prohibida su reproducción y venta

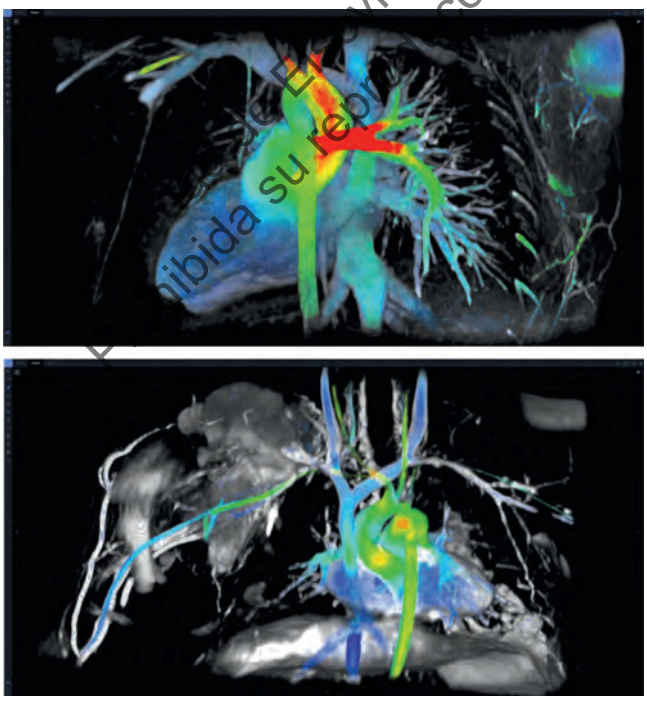

Figura 6.6 El flujo 4D se puede utilizar para observar el flujo sanguíneo y la función cardiaca al mismo tiempo. Con esta técnica se puede obtener una evaluación completa del corazón en 10 minutos. Esto permitirá a los médicos cuantificar el mejor enfoque terapéutico para los pacientes. *www.arterys.com.*

como las mediciones manuales realizadas por expertos, y aumenta la calidad y la resolución de la imagen en menos tiempo. Con estas dos tecnologías combinadas, los archivos que normalmente tardaban días en procesarse en un entorno hospitalario ahora pueden tardar minutos [36]. Arterys utiliza la computación en la nube para ejecutar el procesamiento y el aumento de datos a una velocidad mucho mayor, mientras recopila imágenes de diferentes hospitales, modelos de escáner y pacientes, lo que aumenta la capacidad de generalización del modelo y, por tanto, sus predicciones. Esta funcionalidad también pone en juego la cuestión de la privacidad y seguridad de los datos del paciente. Para abordar este problema, Arterys ha incorporado un sistema llamado servicio de información médica protegida (IMP) que elimina los datos relacionados con la identidad de las imágenes antes de cargarlas en la nube. Por tanto, cuando el personal médico autorizado requiere la identidad de los datos para la evaluación del paciente, el servicio de IMP reconstruye la imagen con los datos de identidad del paciente del servidor seguro del hospital [37]. Por tanto, la imagen sin procesar y sin formato se carga, se convierte en datos DICOM, se reconstruye, se corrige y se aplican las herramientas de posprocesamiento 3D interactivas en tiempo real. Posteriormente, la visualización del flujo, el análisis cuantitativo y el análisis estadístico se realizan en la nube en un corto periodo de 12 minutos [36].

Con la utilización del aprendizaje profundo, la clasificación y la segmentación son específicamente las que se mejoran al ahorrar tiempo y hacer que el proceso sea más eficiente. La segmentación de los ventrículos del corazón es una de las tareas que más tiempo requiere en la resonancia magnética cardiaca. Según médicos experimentados, se tarda aproximadamente 1 hora en segmentar los ventrículos izquierdo y derecho, ~30 minutos por ventrículo [38]. El modelo Arterys segmenta automáticamente el interior y el exterior de los ventrículos con la misma precisión que los anotadores expertos en solo 10 segundos [39]. A continuación, se identifican las capas más adecuadas para que el modelo de aprendizaje profundo produzca los resultados más precisos en un marco de tiempo apropiado para la inferencia, ya que más capas harían que el modelo sea más preciso, pero puede llevar más tiempo procesar [37].

El modelo Arterys también reduce el tiempo medio total de exploración de 71 a 52 minutos. Esto incluye una reducción significativa de la anestesia utilizada en pacientes pediátricos y la eliminación de las respiraciones contenidas durante los exámenes de resonancia magnética. En comparación con la tarea manual convencional, el modelo de IA puede procesar enormes volúmenes de nuevos datos de imágenes. Además, se extraen conocimientos clínicos nuevos y relevantes de las relaciones complejas y no lineales de los puntos de datos en los modelos de aprendizaje profundo. La plataforma se desarrolló junto con los usuarios finales para integrar el sistema en su flujo de trabajo diario, capturando sus entradas e implementando cambios para mejorar el flujo de trabajo [37].

Propiedad de Elsevier
Prohibida su reproducción y venta

© Elsevier. Fotocopiar sin autorización es un delito.

Actualmente, Arterys tiene como objetivo predecir la respuesta al tratamiento y el riesgo de progresión de la enfermedad en imágenes de ensayos clínicos, así como agregar datos de resultados de laboratorio para individualizar la atención del paciente mediante la construcción de un modelo predictivo más completo [37]. El modelo también se ha extrapolado para analizar los pulmones, el hígado y la radiografía de tórax, mientras se desarrollan plataformas neurológicas y de próstata, creando una *suite* de IA para la atención médica [40,41].

6.7 Perspectivas

Si bien el futuro de la IA en radiología parece muy prometedor, para los radiólogos las cosas serían algo más sombrías, según Geoffrey Hinton, a quien se acredita como una «figura líder en el aprendizaje profundo». Se le cita en la revista The New Yorker diciendo: «Creo que si trabajas como radiólogo eres como Wile E. Coyote en los dibujos animados, ya estás al borde del precipicio, pero aún no has mirado abajo. No hay suelo debajo de ti (...). Es totalmente obvio que en 5 años el aprendizaje profundo va a funcionar mejor que los radiólogos, podrían pasar 10 años (...). Lo dije en un hospital. No fue muy bien (...). Deberían dejar de formar radiólogos ahora». El conocido científico informático y estadístico Andrew Ng compartió reflexiones algo similares. Estos pensamientos también están respaldados, hasta cierto punto, dentro de la propia profesión: el expresidente de la Radiological Society of North America ha *pronosticado* que «dentro de 10 años, un radiólogo no revisará ningún estudio de imágenes médicas hasta que haya sido preanalizado por una máquina». Explica además que las computadoras aún no están tomando el control; las máquinas están ahí para apoyar y no para reemplazar. Si bien todas las afirmaciones anteriores pueden ser ciertas, es importante señalar que existen varias limitaciones en la aplicación actual de la IA en radiología y que todavía está muy orientada a la tarea específica. Es interesante destacar que los algoritmos aprobados por la FDA pueden detectar que no hay fracturas de muñeca presentes en una radiografía de rayos X, pero no identifican que ha habido una carpectomía de la fila proximal. Es decir, que se ha extirpado quirúrgicamente una fila completa de huesos de la muñeca. Esto se debe a que el *software* solo está diseñado para buscar fracturas, por lo que, si bien funciona de manera robusta, tiene sus limitaciones.

Finalmente, planteamos la hipótesis de que la hibridación del campo de la radiología es el resultado más probable en un futuro próximo. Esto implica comprender que, dentro de este campo, la IA aumentará cada vez más las necesidades de los trabajadores de la salud, reducirá la carga para los médicos, integrará todos los datos relevantes del paciente y, en última instancia, conducirá a una mejor experiencia del paciente. A menudo, estos procesos

Propiedad de Elsevier
Prohibida su reproducción y venta

se enfrentan a dilemas que requieren la intervención humana y, por tanto, una «inteligencia colectiva» tanto humana como mecánica puede conducir a un flujo de trabajo más eficiente y cohesionado.

Bibliografía

[1] Onieva Onieva J, González Serrano G, Young TP, Washko GR, Ledesma Carbayo MJ, San José Estépar R. Multiorgan structures detection using deep convolutional neural networks. Progress in biomedical optics and imaging—Proceedings of SPIE, 10574. 2018.

[2] Pang S, et al. A novel YOLOv3-arch model for identifying cholelithiasis and classifying gallstones on CT images. PLoS One 2019;14(6):e0217647.

[3] Hussain Z, Gimenez F, Yi D, Rubin D. Differential data augmentation techniques for medical imaging classification tasks. AMIA Annu Symp Proc 2017;2017:979–84.

[4] Li L-J, et al. , ImageNet: a Large-Scale Hierarchical Image Database, Characterization of natural fibers, View project, Display Wall immersive imagery research, 2009.

[5] Miotto R, Wang F, Wang S, Jiang X, Dudley JT. Deep learning for healthcare: review, opportunities and challenges. Brief Bioinform 2017;19(6):1236–46.

[6] Ker J, Wang L, Rao J, Lim T. Deep learning applications in medical image analysis. IEEE Access 2017;6:9375–9.

[7] Mazurowski MA, Habas PA, Zurada JM, Lo JY, Baker JA, Tourassi GD. Training neural network classifiers for medical decision making: the effects of imbalanced datasets on classification performance. Neural Netw 2008;21:427–36.

[8] Erickson BJ, Korfiatis P, Akkus Z, Kline TL. Machine learning for medical imaging. Radiographics 2017;37(2):505–15.

[9] Zhang L, et al., When unseen domain generalization is unnecessary? Rethinking data augmentation; 2019.

[10] Tajbakhsh N, Jeyaseelan L, Li Q, Chiang J, Wu Z, Ding X. Embracing imperfect datasets: a review of deep learning solutions for medical image segmentation; 2019.

[11] Bowles C, et al., GAN augmentation: augmenting training data using generative adversarial networks; 2018.

[12] Tripathi N, Jadeja A. A survey of regularization methods for deep neural network. Int J Comput Sci Mob Comput 2014;3:429–36.

[13] Lundervold AS, Lundervold A. An overview of deep learning in medical imaging focusing on MRI. Z Med Phys 2019;29(2):102–27.

[14] Zech JR, et al. Variable generalization performance of a deep learning model to detect pneumonia in chest radiographs: a cross-sectional study. PLoS Med 2018;15:e1002683.

[15] Torrey L, Shavlik J. Transfer learningHandbook of research on machine learning applications. IGI Global 2009;.

[16] Shorten C, Khoshgoftaar TM. A survey on image data augmentation for deep learning. J Big Data 2019;6:60.

[17] Lu J, Behbood V, Hao P, Zuo H, Xue S, Zhang G. Transfer learning using computational intelligence: a survey. Knowl Based Syst 2015;80:14–23.

[18] Pan SJ, Yang Q. A survey on transfer learning. IEEE Trans Knowl Data Eng 2010;22(10):1345–59.

[19] Kushibar K, et al. Supervised domain adaptation for automatic sub-cortical brain structure segmentation with minimal user interaction. Sci Rep 2019;9.

[20] Huo Y, Xu Z, Bao S, Assad A, Abramson RG, Landman BA. Adversarial synthesis learning enables segmentation without target modality ground truth. Proceedings— International symposium on biomedical imaging, 2018. 2018. p. 121720.

[21] Csurka G. Domain adaptation for visual applications: a comprehensive survey. Domain adaptation in computer vision applications. Springer; 2017.

[22] Kouw WM, Loog M. A review of domain adaptation without target labels. IEEE Trans Pattern Anal Mach Intell 2019;.

[23] Lee JG, et al. Deep learning in medical imaging: general overview. Korean J Radiol 2017;18(4):570–84.

Propiedad de Elsevier
Prohibida su reproducción y venta

© Elsevier. Fotocopiar sin autorización es un delito.

[24] Chartrand G, et al. Deep learning: a primer for radiologists. Radiographics 2017;37(7):2113–31.
[25] Board of the Faculty of Clinical Radiology. Clinical Radiology UK Workforce Census Report 2018, R Coll Radiol, April 2018.
[26] Kao E-F, Liu G-C, Lee L-Y, Tsai H-Y, Jaw T-S. Computer-aided detection system for chest radiography: reducing report turnaround times of examinations with abnormalities. Acta Radiol 2015;56(6):696–701.
[27] Robinson PJ, Wilson D, Coral A, Murphy A, Verow P. Variation between experienced observers in the interpretation of accident and emergency radiographs. Br J Radiol 1999;72(856):323–30.
[28] Hanna TN, Lamoureux C, Krupinski EA, Weber S, Johnson JO. Effect of shift, schedule, and volume on interpretive accuracy: a retrospective analysis of 2.9 million radiologic examinations. Radiology 2018;287:205–12.
[29] Bruno MA, Walker EA, Abujudeh HH. Understanding and confronting our mistakes: the epidemiology of error in radiology and strategies for error reduction. Radiographics 2015;35(6):1668–76.
[30] C. Brestel, M. Cohen-sfaty, RadBot-CXR: classification of four clinical finding categories in chest X-ray using deep learningMedical Imaging with Deep Learning (MIDL 2018). 2018.1-9.
[31] Kiadaliri AA, Englund M. Mortality with musculoskeletal disorders as underlying cause in Sweden 1997-2013: a time trend aggregate level study. BMC Musculoskelet Disord 2016;17(1):163.
[32] Liu W, Yang L-H, Kong X-C, An L-K, Wang R. Meta-analysis of osteoporosis: fracture risks, medication and treatment. Minerva Med 2015;106(4):203–14.
[33] Bar A, Wolf L, Bergman Amitai O, Toledano E, Elnekave E. Compression fractures detection on CT. Medical imaging 2017: computer-aided diagnosis. 2017.
[34] Joyce YLB, Jiajun XM, Flemming FP, Ji-Bin LMF. CMUT/CMOS-based Butterfly iQ—a portable personal sonoscope. Adv Ultrasound Diagnosis Ther 2019;3:115.
[35] Marr B. First FDA approval for clinical cloud-based deep learning in healthcare. Forbes. 2017.
[36] Arterys. Transforming cardiac MR: advances in AI, 4D flow and cloud computing; 2018.
[37] Natarajan P, Frenzel JC, Smaltz DH, Leibowitz C. Arterys: deep learning for medical imagingDemystifying big data and machine learning for healthcare. CRC Press; 2018. 169-173.
[38] Lieman-Sifry J, Le M, Lau F, Sall S, Golden D, FastVentricle: cardiac segmentation with ENet.
[39] Suinesiaputra A, et al. Quantification of LV function and mass by cardiovascular magnetic resonance: multi-center variability and consensus contours. J Cardiovasc Magn Reson 2015;17(1):63.
[40] Platform - Arterys.
[41] Arterys FDA clearance for liver AI and lung AI lesion spotting software | Medgadget.

Propiedad de Elsevier
Prohibida su reproducción y venta