سیستم های اطلاعاتی هوشمند
نشریه علمی دانشگاه آزاد اسلامی
مجلد۴ شماره ۸
صفحات.۸۳ - ۹۸
مقاله عادی

شبکه‌های حسگر بی‌سیم هوشمند مبتنی بر هوش مصنوعی برای مراقبت‌های بهداشتی هوشمند و پایش بیمار: چالش‌ها، فناوری‌ها و روندهای نوین

مهدی میرزائی[۱]، منصور اسماعیل پور[۲]

[۱]دانشجوی کارشناسی، گروه مهندسی کامپیوتر، واحد همدان، دانشگاه آزاد اسلامی، همدان، ایران
mahdi.mirzaei2107@iau.ir
[۲] دانشیار گروه کامپیوتر، دانشکده فنی مهندسی، واحد همدان، دانشگاه آزاد اسلامی، همدان، ایران
esmaeilpour@iau.ac.ir

چکیده:

همگرایی هوش مصنوعی (AI) و شبکه‌های حسگر بی‌سیم (WSN) در حال ایجاد تحولی بنیادین در حوزه سلامت و گذار از مدل‌های درمانی واکنشی به پارادایم مراقبت پیش‌دستانه و شخصی‌سازی‌شده است. اهمیت این موضوع در توانایی این فناوری‌ها برای پاسخ به فشارهای جهانی نظام سلامت، از جمله جمعیت سالخورده، شیوع بیماری‌های مزمن و هزینه‌های فزاینده، نهفته است. این مقاله با هدف ارائه‌ی یک تحلیل جامع و چندرشته‌ای از این حوزه، به بررسی چالش‌ها، فناوری‌های کلیدی و روندهای نوین می‌پردازد.روش‌شناسی این پژوهش بر پایه‌ی یک بررسی تحلیلی و جامع از وضعیت فعلی فناوری، از طریق کالبدشکافی نظام‌مند چالش‌ها در سه سطح دستگاه، یادگیری و سیستم استوار است. این مقاله با ارائه‌ی تحلیل‌های تطبیقی دقیق از فناوری‌های توانمندساز در هر لایه از معماری اینترنت اشیاء پزشکی (IoMT) از حسگرهای پوشیدنی و پروتکل‌های ارتباطی مانند BLE و LoRaWAN گرفته تا الگوریتم‌های هوش مصنوعی مانند CNN-LSTM و یادگیری تقویتی یک نقشه راه جامع ارائه می‌دهد. یافته‌های کلیدی نشان می‌دهد که چالش اصلی مهندسی در این حوزه، یک (معضل سه‌گانه) میان غنای داده، ماندگاری دستگاه (عمر باتری) و بهینگی شبکه است. علاوه بر این، پیاده‌سازی موفقیت‌آمیز این سیستم‌ها به یک (پیوند سه‌گانه‌ی اعتماد، امنیت، شخصی‌سازی) وابسته است که بر لزوم پیشرفت همزمان در هوش مصنوعی توضیح‌پذیر (XAI)، راهکارهای حافظ حریم خصوصی مانند یادگیری فدرال، و شخصی‌سازی درمان‌ها تأکید دارد.نوآوری مقاله در ارائه‌ی یک چارچوب تحلیلی کل‌نگر و یکپارچه است که به جای بررسی مجزای فناوری‌ها، بر روابط هم‌زیستی و تنش‌های متقابل میان آن‌ها تمرکز می‌کند. این رویکرد، بینش‌های عملیاتی برای پژوهشگران، پزشکان و سیاست‌گذاران جهت هدایت توسعه‌ی نسل آینده‌ی سیستم‌های سلامت هوشمند فراهم می‌آورد.

کلمات کلیدی:

شبکه‌های حسگر بی‌سیم، هوش مصنوعی، مراقبت‌های بهداشتی هوشمند، یادگیری عمیق، حسگرهای پوشیدنی، پایش بیمار از راه دور.

۱- مقدمه

چشم‌انداز جهانی مراقبت‌های بهداشتی در حال یک تحول بنیادین از مدل درمانیِ واکنشی به پارادایمی نوین با ماهیت پیش‌دستانه، شخصی‌سازی‌شده و پیشگیرانه است. نیروی محرکه ی این دگرگونی، همگرایی دو فناوری قدرتمند است: شبکه‌های حسگر بی‌سیم (WSN) که امکان پایش مداوم و فراگیر وضعیت فیزیولوژیک را فراهم می‌کنند و هوش مصنوعی (AI) که قدرت تحلیل ژرف و استخراج الگوهای پیچیده از داده‌ها را دارد. ترکیب این دو فناوری در حوزه سلامت از آن جهت مهم است که پاسخی مستقیم به فشارهای حیاتی نظام سلامت جهانی، از جمله جمعیت سالخورده، شیوع روزافزون بیماری‌های مزمن و هزینه‌های سرسام‌آور درمانی، ارائه می‌دهد. با این حال، مسئله‌ی اصلی صرفاً گردآوری داده نیست، بلکه پر کردن شکاف عمیق میان سیلاب داده‌های خامِ تولید شده توسط حسگرها و دستیابی به بینش‌های بالینیِ عملیاتی و قابل اعتماد است. چالش محوری، مدیریت و تحلیل هوشمندانه‌ی این (کلان‌داده) در چارچوب محدودیت‌های شدید منابع (انرژی، محاسبات) در دستگاه‌های حسگر و با رعایت بالاترین استانداردهای ایمنی، امنیت و حریم خصوصی بیمار است[1].

اگرچه مطالعات پیشین پتانسیل عظیم این حوزه را نشان داده‌اند، اما شکاف‌های علمی و فنی قابل توجهی همچنان باقی است. بسیاری از سیستم‌های موجود از هوشمندی محدودی برخوردارند و چالش‌های پایداری در دستیابی به اعتبارسنجی

بالینی در دنیای واقعی، تضمین کیفیت داده‌ها، و مستحکم‌سازی سیستم‌ها در برابر تهدیدات امنیتی وجود دارد. این مقاله با هدف پوشش دادن این خلأها، اهداف زیر را دنبال می‌کند:

۱. کالبدشکافی نظام‌مند چالش‌ها و فرصت‌ها: شناسایی و تحلیل موانع فنی و مفهومی اصلی در سطوح دستگاه، یادگیری ماشین و یکپارچه‌سازی سیستم.

۲. ارائه تحلیل تطبیقی از فناوری‌های کلیدی: بررسی و مقایسه‌ی دقیق فناوری‌های توانمندساز در هر لایه از معماری اینترنت اشیاء پزشکی (IoMT)، از حسگرها و پروتکل‌های ارتباطی گرفته تا الگوریتم‌های هوش مصنوعی[2].

۳. شناسایی و ترکیب روندهای نوظهور: بررسی عمیق روندهای آینده‌ساز مانند هوش مصنوعی توضیح‌پذیر (XAI)، یادگیری فدرال و بلاک‌چین که نسل بعدی مراقبت‌های بهداشتی هوشمند را شکل خواهند داد.

۴. ارائه بینش‌های عملیاتی: فراهم آوردن یک نقشه راه راهبردی برای پژوهشگران، مهندسان، پزشکان و سیاست‌گذاران.

برای دستیابی به اهداف فوق، ساختار مقاله به شرح زیر سازماندهی شده است: بخش ۱ به تشریح اکوسیستم چالش‌ها و فرصت‌هایی می‌پردازد که چشم‌انداز مراقبت‌های بهداشتی هوشمند را تعریف می‌کنند. بخش ۲ یک بررسی فنی عمیق و تطبیقی از فناوری‌های اصلی در لایه‌های حسگری، ارتباطات و هوشمندی ارائه می‌دهد. بخش ۳ روندهای نوظهور و افق آینده را با تمرکز بر نسل بعدی فناوری‌ها و روش‌شناسی‌ها بررسی می‌کند. در نهایت، بخش ۴ یافته‌های گزارش را جمع‌بندی کرده و مجموعه‌ای از توصیه‌های راهبردی برای جهت‌دهی به تحقیقات و سیاست‌گذاری‌های آینده عرضه می‌دارد.

۲- پیشینه پژوهش

مفهوم استفاده از شبکه‌های حسگر بی‌سیم (WSN) برای کاربردهای بهداشتی، موضوع جدیدی نیست و سابقه‌ی تحقیقات در این زمینه به بیش از یک دهه پیش بازمی‌گردد. مطالعات اولیه، همان‌طور که در مرورهایی مانند [۳] مستند شده، عمدتاً بر جایگزینی سیستم‌های پایش سنتیِ کابلی با معادل‌های بی‌سیم متمرکز بودند. این تحقیقات اولیه بر کاربردهای بنیادین مانند پایش علائم حیاتی بیمار و تشخیص سقوط با استفاده از فناوری‌های کوتاه‌بُرد مانند ZigBee و Bluetooth تمرکز داشتند [۴]. اگرچه این سیستم‌ها با افزایش تحرک بیمار و کاهش ناراحتی، گام مهمی به شمار می‌رفتند، اما نقد اصلی وارد بر آن‌ها، برخورداری از هوشمندی محدود بود و اغلب صرفاً به عنوان ابزاری برای انتقال داده عمل می‌کردند تا تحلیل و تفسیر هوشمند آن.

با یکپارچه‌سازی عمیق هوش مصنوعی (AI)، جهشی تحول‌آفرین در این حوزه رخ داد. کتاب ها و مقالات مروری جدیدتر، مانند [۶،۵]، این گرایش را به خوبی شناسایی کرده و به تشریح پتانسیل عظیم به‌کارگیری الگوریتم‌های یادگیری ماشین برای وظایف پیچیده‌تری همچون تشخیص زودهنگام بیماری، پیش‌بینی آنی رویدادهای نامطلوب و شخصی‌سازی درمان پرداخته‌اند. با این حال، علی‌رغم ارزش بالای این مرورها در به تصویر کشیدن وضعیت فعلی، آن‌ها اغلب چالش‌های موجود را به صورت فهرستی از مسائل مجزا (مانند امنیت، کیفیت داده، مصرف انرژی) ارائه می‌دهند. نقد اصلی بر این رویکرد آن است که این مطالعات کمتر به تحلیل روابط هم‌زیستی و تنش‌های متقابل میان این چالش‌ها در یک چارچوب یکپارچه پرداخته‌اند.

ارزش افزوده‌ی مقاله حاضر دقیقاً در همین نقطه آشکار می‌شود. این مقاله فراتر از یک فهرست‌بندی صرف از فناوری‌ها و چالش‌ها، یک چارچوب تحلیلی کل‌نگر (Holistic) ارائه می‌دهد. نوآوری اصلی آن، صورت‌بندی چالش‌های مهندسی در قالب معضل سه‌گانه‌ی محدودیت منابع (توازن میان غنای داده، ماندگاری دستگاه و بهینگی شبکه) و الزامات پیاده‌سازی در قالب پیوند سه‌گانه‌ی اعتماد-امنیت-شخصی‌سازی است. برخلاف مرورهای پیشین که ممکن است بر یک لایه‌ی خاص (مثلاً پروتکل‌های ارتباطی) یا یک الگوریتم خاص تمرکز کنند، این گزارش به تحلیل تأثیرات آبشاری تصمیمات در سرتاسر پشته‌ی معماری اینترنت اشیاء پزشکی (IoMT) می‌پردازد. این دیدگاه یکپارچه، درک عمیق‌تری از توازن‌های (trade-offs) ضروری در طراحی سیستم‌های سلامت هوشمند فراهم کرده و یک نقشه راه عملیاتی‌تر برای پژوهشگران، مهندسان و سیاست‌گذاران ارائه می‌دهد.

۳- روش‌شناسی

این مقاله یک بررسی مروری جامع و تحلیلی (Comprehensive Analytical Review) است که با هدف ارائه‌ی تصویری کل‌نگر از وضعیت فعلی، چالش‌ها و روندهای آینده در حوزه‌ی شبکه‌های حسگر بی‌سیم هوشمند برای کاربردهای سلامت انجام شده است. رویکرد این پژوهش، فراتر از یک خلاصه‌سازی صرف، بر سنتز موضوعی (Thematic Synthesis) و تحلیل انتقادی ادبیات علمی موجود متمرکز است تا یک چارچوب مفهومی یکپارچه ارائه دهد.

برای اطمینان از پوشش جامع و مرتبط، یک راهبرد جستجوی ساختاریافته برای شناسایی مقالات کلیدی در پایگاه‌های داده علمی معتبر (مانند IEEE Xplore, PubMed, ACM Digital Library, و Scopus) به کار گرفته شد. جستجو بر اساس ترکیبی از کلیدواژه‌های اصلی و مفاهیم موضوعی در سه حوزه اصلی انجام شد:

فناوری‌های پایه: " Wireless Sensor Networks" (WSN), "Body Area Networks" (BAN), "Wearable Sensors", "IoT".

هوشمندی و تحلیل: " Artificial Intelligence" (AI), "Machine Learning" (ML), "Deep Learning", "Reinforcement Learning", ""Federated Learning".

حوزه کاربرد: " Smart Healthcare", "Patient Monitoring", ""eHealth", "mHealth", "IoMT".

مقالات مروری و پیمایشی (Review and Survey Papers) که وضعیت فعلی حوزه را ترسیم می‌کنند. مقالات پژوهشی فنی که به معرفی یک فناوری، پروتکل یا الگوریتم خاص در چارچوب سیستم‌های سلامت هوشمند پرداخته‌اند. مطالعاتی که به طور مشخص بر یکپارچه‌سازی AI و WSN تمرکز دارند. مقالاتی که به تحلیل چالش‌های کلیدی مانند امنیت، حریم خصوصی، محدودیت منابع و قابلیت همکاری می‌پردازند. فرآیند انتخاب مقالات از یک رویکرد چند مرحله‌ای، مشابه منطق دیاگرام PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses)، پیروی کرد.

شناسایی (Identification): مقالات اولیه بر اساس جستجوی کلیدواژه‌ها شناسایی شدند.

غربالگری (Screening): عناوین و چکیده‌ها برای حذف موارد تکراری و آشکارا نامرتبط بررسی شدند.

ارزیابی صلاحیت (Eligibility): متن کامل مقالات باقی‌مانده برای بررسی دقیق بر اساس معیارهای ورود و خروج مطالعه شد.

ورود نهایی (Inclusion): مقالات نهایی که تمامی معیارها را داشتند، برای تحلیل و سنتز نهایی انتخاب شدند.

پس از انتخاب نهایی، اطلاعات کلیدی از هر مقاله استخراج و در یک چارچوب تحلیلی دسته‌بندی شد. این چارچوب بر اساس لایه‌های معماری سیستم (حسگری، ارتباطات، هوشمندی) و موضوعات مفهومی (چالش‌ها، فرصت‌ها، و روندهای نوظهور) بنا نهاده شد. در نهایت، به جای خلاصه‌سازی هر مقاله به صورت مجزا، یافته‌های استخراج‌شده با یکدیگر سنتز شدند تا روایت تحلیلی و یکپارچه‌ای که در این مقاله ارائه شده است، شکل گیرد. این رویکرد امکان شناسایی شکاف‌های پژوهشی و ارائه توصیه‌های راهبردی را فراهم آورد.

۴- تحلیل روش

۴-۱ اکوسیستم مراقبت‌های بهداشتی هوشمند: چشم‌اندازی از چالش‌ها و فرصت‌ها

ایجاد یک سیستم مراقبت بهداشتی هوشمند که استوار (robust)، قابل اعتماد (reliable) و قابل اطمینان (trustworthy) باشد، تلاشی پیچیده است که توسط شبکه‌ای درهم‌تنیده از چالش‌های متقابل تعریف می‌شود. این چالش‌ها صرفاً مسائل فنی قابل حل به صورت مجزا نیستند؛ بلکه نمایانگر تنش‌های بنیادین میان الزاماتِ رقیب هستند. با این حال، دقیقاً همین چالش‌ها هستند که به نوآوری دامن می‌زنند و چشم‌اندازی حاصلخیز از فرصت‌ها برای فناوری‌ها، معماری‌ها و روش‌شناسی‌های جدید ایجاد می‌کنند. این بخش، این محیط پیچیده را با تحلیل چالش‌های بنیادین در سطوح دستگاه، یادگیری و سیستم، و سپس بررسی فرصت‌های کلیدی که در پاسخ به این چالش‌ها پدیدار می‌شوند، کالبدشکافی می‌کند.

دشواری‌های پیاده‌سازی مؤثر شبکه‌های حسگر بی‌سیم مبتنی بر هوش مصنوعی در حوزه‌ی سلامت را می‌توان به طور نظام‌مند در سه حوزه دسته‌بندی کرد: موانع فیزیکی و سطح شبکه‌ایِ زیرلایه‌ی اینترنت اشیاء (IoT substrate)، مسائل الگوریتمی و داده محور در هسته‌ی یادگیری ماشین، و مشکلات امنیت و یکپارچه‌سازی که در نقطه‌ی تلاقی این دو پدید می‌آیند [۷].

این‌ها محدودیت‌های "سطح فیزیکی" هستند که توسط سخت‌افزار و محیط بی‌سیم در زیر لایه اینترنت اشیاء تحمیل می‌شوند.

محدودیت منابع (Resource Constraints): بنیادین‌ترین و فراگیرترین چالش، محدودیت ذاتی گره‌های حسگر است. این دستگاه‌ها، به‌ویژه آن‌هایی که برای کاربردهای پوشیدنی یا کاشتنی طراحی شده‌اند، از نظر انرژی (عمر باتری)، قدرت محاسباتی و حافظه‌ی ذخیره‌سازی به شدت محدود هستند [۷]. عمر باتری یک دغدغه‌ی اصلی است، زیرا نیاز به شارژ مجدد یا تعویض مکرر برای کاربردهای پایش مداوم و بلندمدت، غیرعملی بوده و می‌تواند روند مراقبت را مختل کند [۸]. این کمبود منابع، بر تمام انتخاب‌های دیگر در طراحی، از انتخاب پروتکل‌های ارتباطی گرفته تا پیچیدگی الگوریتم‌های هوش مصنوعی که می‌توانند به صورت محلی (locally) اجرا شوند، تأثیر می‌گذارد.

قابلیت اطمینان و تأخیر شبکه (Network Reliability and Latency): کاربردهای مراقبت بهداشتی هوشمند، به‌خصوص آن‌هایی که شامل تشخیص اضطراری یا مداخله‌ی آنی هستند، نیازمند پیوندهای ارتباطی بسیار قابل اعتماد و غالباً با تأخیر کم هستند [۷]. کانال‌های بی‌سیم ذاتاً در برابر تداخل، محوشدگی (fading) و قطعی آسیب‌پذیرند. در یک بستر بالینی، یک بسته‌ی داده‌ی از دست رفته یا یک هشدار تأخیردار صرفاً یک زحمت کوچک نیست؛ بلکه می‌تواند عواقب تهدیدکننده‌ی حیات به همراه داشته باشد.

مدیریت و کیفیت داده‌ها (Data Management and Quality): عملکرد مداوم حسگرهای ناهمگون، حجم عظیمی از داده‌ها را تولید می‌کند که مشخصه‌ی آن تنوع و سرعت بالا است و یک مسئله‌ی مدیریتی مهم «کلان‌داده» (Big Data) را مطرح می‌کند [۹]. یک چالش ظریف‌تر اما به همان اندازه حیاتی، تضمین کیفیت داده است. این امر شامل وظیفه‌ی دشوار تمایز سیگنال‌های فیزیولوژیک واقعی از نویز، آرتیفکت‌های حرکتی (motion artifacts) یا تداخلات محیطی است. به عنوان مثال، سیستمی که برای تشخیص سقوط طراحی شده است، باید به طور قابل اعتمادی یک سقوط واقعی را از نشستن سریع کاربر تشخیص دهد، زیرا هشدارهای کاذب می‌توانند منجر به «خستگی ناشی از هشدار» (alert fatigue) و از بین رفتن اعتماد به سیستم شوند [۱۰].

قابلیت همکاری و استانداردسازی (Interoperability and Standardization): چشم‌انداز کنونی اینترنت اشیاء پزشکی (IoMT) از هم گسیخته است و فاقد استانداردهای پذیرفته‌شده‌ی جهانی برای فرمت‌های داده، ارتباطات دستگاه و پروتکل‌های امنیتی است. این "برج بابل" سیستم‌های اختصاصی، مانع یکپارچه‌سازی بی‌وقفه دستگاه‌های ساخت تولیدکنندگان مختلف شده و "سیلوهای داده" (data silos) ایزوله ایجاد می‌کند که مانع تحلیل داده‌ی کل‌نگر و در سطح کل سیستم شده و ساخت مجموعه داده‌های بزرگ و متنوع برای آموزش مدل‌های هوش مصنوعی استوار (robust) را دشوار می‌سازد [۷].

چالش‌هایی هم در هسته یادگیری ماشین به داده‌ها و الگوریتم‌هایی مربوط می‌شوند که هوشمندی سیستم را تشکیل می‌دهند.

آماده‌سازی و عدم توازن داده‌ها (Data Preparation and Imbalance): داده‌های بالینی دنیای واقعی، طبیعتی ذاتاً آشفته و پیچیده دارند. این داده‌ها اغلب بدون ساختار، حاوی نویز و مقادیر گمشده هستند و مهم‌تر از همه، به شدت

نامتوازن می‌باشند. به عنوان مثال، در یک مجموعه داده از ضربان‌های قلب، تعداد نمونه‌های (نرمال) بسیار بیشتر از نمونه‌های (آریتمیک) خواهد بود. اگر این عدم توازن کلاس (class imbalance) به درستی مدیریت نشود، می‌تواند مدل‌های یادگیری ماشین را به شدت دچار سوگیری (bias) کند، به طوری که در تشخیص موارد رایج بسیار خوب عمل کنند اما در شناسایی رویدادهای نادر و غالباً حیاتی‌تر شکست بخورند [۵].

عملکرد و تعمیم‌پذیری مدل (Model Performance and Generalizability): توسعه‌ی یک مدل هوش مصنوعی که در یک مجموعه داده‌ی آزمایشی به دقت بالا دست یابد، تنها قدم اول است. چالش بسیار بزرگ‌تر، حصول اطمینان از این است که مدل، استوار بوده و به خوبی به داده‌های جدید و دیده‌نشده از جمعیت‌های متنوع بیماران تعمیم می‌یابد [۷]. مدلی که عمدتاً بر روی داده‌های یک گروه جمعیتی خاص آموزش دیده باشد، ممکن است هنگام اعمال بر روی گروهی دیگر، دچار افت عملکرد قابل توجهی شود که این امر نگرانی‌های جدی در مورد انصاف و برابری در ارائه‌ی خدمات بهداشتی ایجاد می‌کند [۱۱].

ابعاد اخلاقی و حقوقی (مسئله‌ی "جعبه سیاه"): بسیاری از قدرتمندترین مدل‌های هوش مصنوعی، به‌ویژه در حوزه‌ی یادگیری عمیق، مانند «جعبه‌های سیاه» (black boxes) عمل می‌کنند. آن‌ها می‌توانند پیش‌بینی‌های فوق‌العاده دقیقی انجام دهند، اما فرآیندهای تصمیم‌گیری داخلی‌شان کدر بوده و به راحتی توسط انسان قابل تفسیر نیستند. این فقدان توضیح‌پذیری (explainability) یک مانع بزرگ برای پذیرش بالینی است. پزشکان تمایلی به اعتماد و پذیرش مسئولیت توصیه‌های سیستمی که استدلال آن را درک نمی‌کنند، ندارند. این عدم شفافیت همچنین معضلات حقوقی و اخلاقی قابل توجهی در زمینه‌ی پاسخگویی و مسئولیت‌پذیری در مواقعی که یک تصمیمِ مبتنی بر هوش مصنوعی منجر به نتیجه‌ای منفی می‌شود، ایجاد می‌کند [۱۲].

چالش‌هایی نیز در سطح یکپارچه سازی سیستم IOT+ML پیچیده در نقطه‌ی تلاقی سخت‌افزار فیزیکی و نرم‌افزار هوشمند پدیدار می‌شوند.

امنیت و حریم خصوصی (Security and Privacy): این مورد را می‌توان به عنوان بزرگترین مانع واحد بر سر راه پذیرش گسترده و اعتماد عمومی به سیستم‌های مراقبت بهداشتی هوشمند دانست. انتقال داده‌های بسیار حساس و شخصی سلامت بر بستر کانال‌های بی‌سیم، این سیستم‌ها را به هدفی اصلی برای طیف گسترده‌ای از تهدیدات امنیتی تبدیل می‌کند. این تهدیدات شامل حملات غیرفعال (passive) مانند استراق سمع برای رهگیری داده‌های بیمار، و حملات فعال (active) مانند دستکاری داده‌ها (که می‌تواند تشخیص پزشکی را تغییر دهد)، حملات مرد میانی (man-in-the-middle)، و حملات منع سرویس (denial-of-service) که می‌توانند یک سرویس حیاتی پایش را از کار بیندازند، می‌شود [۶]. یکپارچه‌سازی یادگیری ماشین، سطوح حمله‌ی (attack surfaces) جدید و پیچیده‌ای را معرفی می‌کند. این‌ها شامل مسموم‌سازی داده‌ها (data poisoning)، که در آن مهاجم داده‌های مخرب را به مجموعه آموزشی تزریق می‌کند تا مدل نهایی را خراب کند، و حملات وارون‌سازی مدل (model inversion attacks)، که در آن مهاجم تلاش می‌کند تا با تحلیل پارامترهای مدلِ آموزش‌دیده، داده‌های حساس آموزشی (مانند سوابق پزشکی بیمار) را بازسازی کند، می‌شود [۱۳,۱۲].

یادگیری پیوسته‌ی آنی (Real-time Continuous Learning): یک سیستم سلامت هوشمند ایده‌آل نباید ایستا (static) باشد؛ بلکه باید از داده‌های جدید بیاموزد و عملکرد خود را در طول زمان تطبیق دهد. با این حال، پیاده‌سازی این یادگیری «آنلاین» یا پیوسته بر روی دستگاه‌های با منابع محدود، یک مسئله‌ی تحقیقاتی باز است. یک موضوع کلیدی در این زمینه (فراموشی فاجعه‌بار) (catastrophic forgetting) است، که در آن مدلی که با اطلاعات جدید به‌روز می‌شود، به طور ناگهانی دانشی را که قبلاً آموخته بود از دست می‌دهد و این امر منجر به افت ناگهانی و شدید عملکرد می‌شود [۵].

تحلیل کلان‌داده در لبه (Big Data Analytics at the Edge): در حالی که انتقال محاسبات به نزدیکی منبع داده (رایانش لبه یا edge computing) یک راه‌حل امیدوارکننده برای کاهش تأخیر و حفظ حریم خصوصی است، انجام تحلیل‌های پیچیده‌ی کلان‌داده و آموزش مدل‌های یادگیری ماشین پیشرفته بر روی دستگاه‌های لبه با منابع محدود، همچنان بسیار دشوار است. یک تنش بنیادین میان تمایل به استفاده از مدل‌های پیچیده و قدرتمند و بودجه‌ی محاسباتی محدود سخت‌افزار لبه وجود دارد [۷].

۴-۲ غلبه بر موانع: چشم‌اندازی از فرصت‌ها

چالش‌های عظیمی که در بالا شرح داده شد، موانعی غیرقابل عبور نیستند، بلکه کاتالیزورهایی قدرتمند برای نوآوری به شمار می‌روند. نیاز به حل این مشکلات، به پیدایش چشم‌اندازی غنی از فرصت‌های تحقیقاتی و پارادایم‌های فناورانه‌ی جدید منجر شده است.

یادگیری ماشین حافظ حریم خصوصی (Privacy-Preserving Machine Learning): نیاز مبرم به حفاظت از حریم خصوصی بیمار و در عین حال بهره‌مندی از داده‌های مقیاس بزرگ، به نوآوری‌های عظیمی در فناوری‌های تقویت‌کننده‌ی حریم خصوصی (privacy-enhancing technologies) دامن زده است.

برجسته‌ترینِ این فناوری‌ها، یادگیری فدرال (Federated Learning - FL) است. این روش، امکان آموزش مشارکتی یک مدل جهانی قدرتمند را در میان چندین موسسه، بدون افشا یا انتقال داده‌های حساس، فراهم می‌آورد و مستقیماً یکی از چالش‌های اصلی حریم خصوصی را برطرف می‌کند [۱۴, ۱۵, ۱۶].

معماری‌های رایانش لبه و مه (Edge and Fog Computing): برای مواجهه با چالش‌های تأخیر شبکه، محدودیت‌های پهنای باند و حریم خصوصی داده‌ها، یک گرایش قدرتمند و شتابان به سمت انتقال محاسبات از ابرِ دوردست به نزدیکی منبع داده وجود دارد. این تغییر معماری، تصمیم‌گیری محلی سریع‌تر را برای رویدادهای حساس به زمان امکان‌پذیر می‌سازد، حجم داده‌هایی را که باید در شبکه منتقل شوند کاهش می‌دهد (که باعث صرفه‌جویی در انرژی و پهنای باند

می‌شود)، و با پردازش داده‌های حساس به صورت محلی به جای ارسال آن‌ها به ابر، حریم خصوصی را تقویت می‌کند [۷].

راهکارهای سبک و بهینه از نظر انرژی (Lightweight and Energy-Efficient Solutions): محدودیت‌های شدید منابع در دستگاه‌های اینترنت اشیاء، موجی از تحقیقات متمرکز بر بهینگی را به راه انداخته است. این تحقیقات شامل توسعه‌ی مدل‌های یادگیری ماشین سبک، مانند شبکه‌های عصبی کوانتیزه‌شده... طراحی الگوریتم‌های تجمیع داده‌ی بهینه از نظر انرژی که به طور هوشمند داده‌ها را قبل از ارسال خلاصه می‌کنند [۱۷]؛ و نوآوری در ریزالکترونیک کم‌توان و طراحی سخت‌افزار، مانند تراشه‌های گیرنده‌ی جدید که ضمن مصرف توان کمینه، در برابر تداخل مقاوم‌تر هستند، می‌شود [۱۸].

قابلیت همکاری معنایی و هماهنگ‌سازی داده‌ها (Semantic Interoperability and Data Harmonization): چالش قابلیت همکاری دستگاه و داده، فرصت مهمی را برای توسعه‌ی مدل‌های داده‌ی استاندارد، هستی‌شناسی‌ها (ontologies) و واژگان مشترک ایجاد می‌کند. دستیابی به این هدف، یک توانمندساز کلیدی برای ساخت مجموعه داده‌های مقیاس بزرگ، باکیفیت و متنوع است که برای آموزش نسل بعدی مدل‌های هوش مصنوعی استوار و تعمیم‌پذیر در حوزه‌ی سلامت مورد نیاز هستند [۷].

پیاده‌سازی اقدامات امنیتی استوار، مانند رمزنگاری پیشرفته، اغلب از نظر محاسباتی سنگین است که این امر مستقیماً با محدودیت‌های منابع در گره‌های حسگر در تضاد است. به عنوان مثال، تکنیک‌هایی مانند رمزنگاری هومومورفیک (homomorphic encryption)، که امکان محاسبه بر روی داده‌های رمزنگاری‌شده را فراهم می‌کنند، تضمین‌های قدرتمندی برای حریم خصوصی ارائه می‌ده دهند اما با سربار محاسباتی قابل توجهی همراه هستند [۶]. به طور مشابه، یادگیری فدرال سربار ارتباطی قابل ملاحظه‌ای را در طول فرآیند به‌روزرسانی مدل تحمیل می‌کند که بر عملکرد شبکه و عمر باتری دستگاه تأثیر می‌گذارد [۱۹].

۴-۳ فناوری‌ها و روش‌شناسی‌های اصلی: موتورهای محرکه‌ی پایش هوشمند

معماری یک شبکه‌ی حسگر بی‌سیم هوشمند مبتنی بر هوش مصنوعی برای کاربردهای بهداشتی، یک پشته‌ی چندلایه است که در آن هر لایه خدمات ضروری را ارائه داده و محدودیت‌هایی را بر لایه‌های دیگر تحمیل می‌کند. درک عمیق از فناوری‌های موجود در هر لایه حسگری، ارتباطات و هوشمندی برای طراحی سیستم‌های مؤثر و قابل اعتماد حیاتی است. انتخاب‌های انجام‌شده در یک لایه، اثرات آبشاری (cascading effects) در سرتاسر پشته به همراه دارد و یک رابطه‌ی هم‌زیستی ایجاد می‌کند که در آن اجزا باید برای عملکرد بهینه، به صورت یکپارچه هم‌طراحی (co-designed) شوند.

برای مثال، انتخاب یک حسگر با وضوح و فرکانس بالا در لایه‌ی حسگری، حجم داده‌ی بزرگی تولید می‌کند که به نوبه‌ی خود نیازمند یک پروتکل ارتباطی با پهنای باند بالا است. این امر مصرف انرژی را افزایش داده و بر عمر باتری دستگاه فشار وارد می‌کند. این فشار ممکن است استفاده از یک مدل هوش مصنوعی بهینه بر روی خود دستگاه (on-device) را در لایه‌ی هوشمندی ضروری سازد تا کاهش داده‌ی محلی را انجام دهد، که این خود بار محاسباتی روی دستگاه را افزایش می‌دهد. این زنجیره از وابستگی‌ها نشان می‌دهد که باید به سیستم به صورت کل‌نگر (holistically) نگریست، نه به عنوان مجموعه‌ای از قطعات مستقل.

۴-۴ لایه‌ی حسگری: از پوشیدنی‌ها تا پایش بدون تماس

این لایه، رابط مستقیم سیستم با دنیای فیزیکی است این حوزه از حسگرهای صُلبِ اولیه به مجموعه‌ی متنوعی از روش‌های حسگری انعطاف‌پذیر، پوشیدنی، کاشتنی و حتی بدون تماس (contactless) تکامل یافته است.

حسگر پوشیدنی مدرن، شگفتی علم مواد و ریزالکترونیک است. همانطور که در یک مرور جامع توضیح داده شده، این دستگاه‌ها اغلب از نانوکامپوزیت‌های پلیمری ساخته می‌شوند که در آن‌ها نانومواد رسانا (مانند نانولوله‌های کربنی یا نانوسیم‌های نقره‌ای) در الاستومرهای انعطاف‌پذیر و کِشسان (مانند سیلیکون) تعبیه شده‌اند [۲۰]. حسگرهای الکتروفیزیولوژیک سیگنال‌های الکتریکی ذاتی بدن را، مانند الکتروکاردیوگرافی (ECG) برای پایش قلب یا الکتروانسفالوگرافی (EEG) برای فعالیت مغز، اندازه‌گیری می‌نمایند [۲۰].

فراتر از حسگرهای روی بدن، تحقیقات در حال بررسی روش‌های کمتر تهاجمی است. این روش‌ها شامل حسگرهای محیطی که محیط کاربر را پایش می‌کنند [۲۱] و فناوری‌های بدون تماس که می‌توانند داده‌های فیزیولوژیک را از راه دور ثبت کنند، می‌شود. تکنیک‌های پیشرو در این زمینه شامل استفاده از اطلاعات وضعیت کانال وای فای (CSI)، که اغتشاشات در سیگنال‌های استاندارد وای فای را برای تشخیص حرکت و حتی نرخ تنفس تحلیل می‌کند [۲۲]، و سیستم‌های رادار تخصصی است که می‌توانند علائم حیاتی را بدون هیچ‌گونه تماس فیزیکی پایش کنند [۲۳].

انتخاب فناوری حسگر، مستلزم یک توازن (trade-off) حیاتی میان عواملی چون دقت، میزان تهاجمی بودن، راحتی کاربر و مصرف توان است. هوش مصنوعی در این لایه نقش مهمی ایفا می‌کند، جایی که یک حسگر به طور ناخواسته تحت تأثیر یک محرک متفاوت قرار می‌گیرد [۲۰].

جدول ۱: مقایسه‌ی فناوری‌های حسگر پوشیدنی برای پایش سلامت

نوع حسگر	سازوکار حسگری	زیست‌نشانگرها/سیگنال‌های کلیدی	نقاط قوت	نقاط ضعف	مصرف توان	کاربردهای نمونه	منابع
الکتروفیزیولوژیک	اندازه‌گیری پتانسیل‌های زیستی (biopotentials) از طریق الکترود	ECG, EEG, EMG, EOG	وفاداری (fidelity) بالای سیگنال، ارتباط بالینی کاملاً تثبیت‌شده	نیازمند تماس مستقیم با پوست، آسیب‌پذیر در برابر آرتیفکت‌های حرکتی، احتمال ایجاد حساسیت پوستی	کم تا متوسط	تشخیص آریتمی، پایش تشنج، تحلیل فعالیت عضلانی، مرحله‌بندی خواب	[4,6,20]
کُرنش/ فشار	پیزومقاومتی، پیزوخازنی، پیزوالکتریک، تریبوالکتریک	حرکت بدن، تنفس، موج پالس، فشار	کشسانی بالا، قابل یکپارچه‌سازی در منسوجات، هزینه کم	پسماند (هیسترزیس) (بازیابی کند)، پاسخ غیرخطی، نگرانی‌های مربوط به دوام	بسیار کم (پیزو/تریبوالکتریک می‌توانند خودتأمین‌کننده انرژی باشند)	تحلیل گام‌برداری، تشخیص سقوط، پایش تنفسی، رابط‌های انسان و ماشین	[4,20,24,25]
بیوشیمیایی	الکتروشیمیایی، ایمونواسی (سنجش ایمنی)، رنگ‌سنجی (Colorimetric)	گلوکز، لاکتات، کورتیزول، pH، الکترولیت‌ها، هورمون‌ها	امکان پایش در سطح مولکولی، امکان دستیابی به ویژگی (specificity) بالا	اغلب تهاجمی (مانند میکروسوزن‌ها)، طول عمر محدود حسگر، چالش‌های گزینش‌پذیری و پایداری	متوسط	پایش مداوم قند خون (CGM)، پایش استرس (کورتیزول)، وضعیت هیدراتاسیون، ردیابی متابولیک	[4,6,20]
نوری	فتوپلتیسموگرافی (PPG)، فلورسانس، جذب	ضربان قلب (HR)، اشباع اکسیژن خون (SpO_2)، فشار خون (BP)	غیرتهاجمی، راحت، مورد استفاده گسترده در دستگاه‌های مصرفی	آسیب‌پذیر در برابر تداخل نور محیط و آرتیفکت‌های حرکتی، دقت می‌تواند با توجه به رنگ پوست متغیر باشد	متوسط	ردیابی تناسب اندام، پایش مداوم ضربان قلب/اشباع اکسیژن، تخمین فشار خون بدون کاف	[4,20,26,27]

5-4 لایه‌ی ارتباطات: پروتکل‌هایی برای انتقال قابل اعتماد داده

این لایه، سیستم عصبی مرکزی شبکه را تشکیل می‌دهد. چشم‌انداز ارتباطات در اینترنت اشیاء پزشکی (IoMT) بسیار متنوع است و هیچ پروتکل واحدی برای تمام کاربردها بهینه نیست [۷].

برای کاربردهایی که به بدن انسان یا محیط اطراف آن محدود می‌شوند. بلوتوث کم‌انرژی (BLE) به یک استاندارد دوفاکتو (استاندارد عملی) تبدیل شده است [۷]. ZigBee، مبتنی بر استاندارد IEEE ۸۰۲.۱۵.۴، یکی دیگر از گزینه‌های محبوب است[۷]. استاندارد IEEE ۸۰۲.۱۵.۶ به طور خاص برای WBANs توسعه یافته است و چندین لایه‌ی فیزیکی با الزامات سخت‌گیرانه برای قابلیت اطمینان و تأخیر کم، تعریف می‌کند [۶].

برای کاربردهایی که نیازمند انتقال داده در فواصل طولانی‌تر هستند فناوری‌های شبکه‌ی گسترده‌ی کم‌توان (LP-WAN) به طور فزاینده‌ای در حال پذیرش هستند. فناوری‌های برجسته‌ی LP-WAN شامل LoRaWAN و اینترنت اشیاء باند باریک (NB-IoT) هستند [۷].

با نگاه به آینده، ظهور G۵ و چشم‌انداز آتی G۶، قابلیت‌های جدیدی را معرفی خواهند کرد مؤلفه‌ی ارتباطات فوق‌العاده قابل اعتماد با تأخیر کم (URLLC) در G۵ برای موارد کاربردی مانند جراحی از راه دور حیاتی است [۱۸, ۲۸].

جدول 2: تحلیل تطبیقی پروتکل‌های ارتباطی بی‌سیم
برای اینترنت اشیاء پزشکی (IoMT)

پروتکل	باند(های) فرکانسی	حداکثر نرخ داده	بُرد معمول	مصرف توان	توپولوژی شبکه	نقاط قوت کلیدی	نقاط ضعف کلیدی	موارد کاربرد ایده‌آل در حوزه‌ی سلامت	منابع
بلوتوث کم‌انرژی (BLE)۵.x	۲.۴ گیگاهرتز	۲~ Mbps	۱۰۰-۱۰ متر	بسیار کم	ستاره‌ای (Star)	فراگیر در گوشی‌های هوشمند، توان بسیار کم برای داده‌های انفجاری (bursty)، هزینه کم.	بُرد محدود، آسیب‌پذیر در برابر تداخل باند ۲.۴ گیگاهرتز.	حسگرهای پوشیدنی متصل به گوشی هوشمند، دستگاه‌های سلامت شخصی، ردیاب‌های فعالیت.	[6,29]
ZigBee (IEEE ۸۰۲.۱۵.۴)	۹۱۵/۸۶۸ مگاهرتز، ۲.۴ گیگاهرتز	۲۵۰ kbps	۱۰۰-۱۰ متر	کم	ستاره‌ای، مِش (Mesh)	قابلیت‌های شبکه‌بندی مِش استوار، توان کم، استانداردسازی‌شده.	نرخ داده‌ی پایین، راه‌اندازی می‌تواند پیچیده باشد، پتانسیل تداخل.	شبکه‌های حسگر داخل بیمارستان، سیستم‌های زندگی به کمک محیط (AAL)، شبکه‌های تشخیص سقوط.	[3,6,29]
Wi-Fi HaLow (IEEE ۸۰۲.۱۱ah)	زیر ۱ گیگاهرتز	۱۵۰ kbps - ۳۴۷ Mbps	تا ۱ کیلومتر	کم تا متوسط	ستاره‌ای	بُرد و نفوذ در دیوار بهتر از وای-فای استاندارد، مبتنی بر IP (IP-native).	توان مصرفی به پایینیِ BLE/ZigBee نیست، پذیرش گسترده‌ی کمتری در حال حاضر دارد.	اتصال دستگاه‌ها در سطح بیمارستان، اتوماسیون ساختمان برای مراکز بهداشتی.	[29]
LoRaWAN	زیر ۱ گیگاهرتز (ISM)	۵۰~ kbps	۵-۲ کیلومتر (شهری)، ۱۵< کیلومتر (روستایی)	بسیار کم	ستاره‌ای از ستاره‌ها (Star-of-Stars)	بُرد بسیار طولانی، عمر باتری عالی (چندین سال)، نفوذ عمیق در فضاهای داخلی.	نرخ داده‌ی بسیار پایین، تأخیر بالا، دسترسی هماهنگ‌نشده به کانال می‌تواند منجر به تصادم (collision) شود.	پایش از راه دور بیماران با وضعیت پایدار، ردیابی هوشمند دارایی‌های بیمارستان، حسگری محیطی.	[9,29]
NB-IoT	باندهای LTE دارای مجوز	۱۶۰~ kbps	۱۰-۱ کیلومتر	بسیار کم	ستاره‌ای	پوشش و نفوذ عالی (استفاده از زیرساخت سلولی)، طیف دارای مجوز قابلیت اطمینان ارائه می‌دهد، امن.	نرخ داده‌ی پایین، وابسته به پشتیبانی اپراتور، پتانسیل هزینه‌ی بالاتر.	دستگاه‌های پایش قند/فشار خون از راه دور، دستگاه‌های هوشمند توزیع قرص، پایش تأسیسات در کلینیک‌ها	[9,29]
G (URLLC)۵	زیر ۶ گیگاهرتز، موج میلی‌متری (mmWave)	۱۰> Gbps	متغیر (برای موج میلی‌متری کوتاه‌تر است)	بالا	ستاره‌ای	تأخیر فوق‌العاده کم (کمتر از ۱ میلی‌ثانیه)، قابلیت اطمینان بسیار بالا، پهنای باند عظیم.	مصرف توان بالا، پوشش محدود در حال حاضر، هزینه‌ی بالای زیرساخت.	جراحی از راه دور (Telesurgery)، واقعیت افزوده/مجازی آنی برای آموزش بالینی، تشخیص از راه دور با وفاداری بالا.	[18,28]

6-4 لایه‌ی هوشمندی: مدل‌ها و الگوریتم‌های یادگیری ماشین

این لایه، موتور شناختی سیستم مراقبت بهداشتی هوشمند است، جایی که داده‌های خام حسگر به اطلاعات معنادار، بینش‌های عملیاتی (actionable insights) و هوشمندی پیش‌بینانه تبدیل می‌شوند. انتخاب مدل هوش مصنوعی یک تصمیم حیاتی است که بر اساس ماهیت داده (مانند سری زمانی، تصویر)، وظیفه‌ی بالینی خاص (مانند طبقه‌بندی، پیش‌بینی، کنترل) و منابع محاسباتی موجود در نقطه‌ی تحلیل (مانند ابر، لبه یا خود دستگاه) تعیین می‌شود. چندین خانواده‌ی متمایز از الگوریتم‌های یادگیری ماشین به عنوان ابزارهایی به‌ویژه قدرتمندend برای کاربردهای بهداشتی ظهور کرده‌اند.

یادگیری عمیق برای داده‌های سلامت سری زمانی (CNN-LSTM): یک روند غالب و بسیار موفق در تحلیل داده‌های سری زمانی حاصل از حسگرهای پوشیدنی استفاده از معماری‌های یادگیری عمیق ترکیبی است که شبکه‌های عصبی کانولوشنی (CNNs) و شبکه‌های حافظه‌ی طولانی کوتاه‌مدت (LSTM) را با هم ترکیب می‌کنند [۲۵,۲۴]. آن‌ها به عنوان استخراج‌کننده‌های ویژگی قدرتمند عمل کرده و الگوهای محلی را بدون نیاز به مهندسی ویژگی دستی شناسایی می‌کنند [۳۰]. سپس توالی ویژگی‌های استخراج‌شده توسط CNN به یک شبکه‌ی LSTM وارد می‌شود [۲۴]. برای افزایش بیشتر عملکرد، بسیاری از مدل‌های پیشرفته (state-of-the-art) از یک سازوکار خودتوجهی (self-attention) استفاده می‌کنند [۲۷,۲۶]. این معماری CNN-LSTM-Attention نتایج پیشرفته‌ای را در طیف گسترده‌ای از کاربردها، به ویژه در تشخیص فعالیت انسان (HAR) و تشخیص سقوط، به اثبات رسانده است[۲۵,۲۴].

جدول ۳ : مقایسه‌ی معماری‌های یادگیری عمیق برای تحلیل داده‌های حسگر پوشیدنی

معماری مدل	عملکرد اصلی	نقاط قوت	نقاط ضعف	پیچیدگی محاسباتی	موارد کاربرد معمول	منابع
CNN مستقل	استخراج ویژگی فضایی از قطعات سیگنال	عالی در یادگیری خودکار ویژگی از داده خام؛ نامتغیر نسبت به انتقال (translation invariant)؛ از نظر محاسباتی برای استخراج ویژگی بهینه است.	در مدل‌سازی وابستگی‌های زمانی بلندمدت ضعیف عمل می‌کند؛ نیازمند پنجره‌های ورودی با اندازه‌ی ثابت است.	متوسط	طبقه‌بندی تصویر-مانند قطعات سیگنال (مثلاً اسپکتروگرام‌ها)، تشخیص ناهنجاری پایه در پنجره‌های ثابت.	[30]
LSTM مستقل	مدل‌سازی توالی زمانی	عالی در ثبت وابستگی‌های بلندمدت و زمینه در داده‌های متوالی؛ قابلیت پردازش توالی‌ها با طول متغیر.	آموزش آن بر روی توالی‌های بسیار طولانی می‌تواند کند باشد؛ در استخراج ویژگی از سیگنال‌های خام و فرکانس-بالا کمتر مؤثر است.	زیاد	پیش‌بینی سری‌های زمانی، مدل‌سازی پیشرفت بیماری از روی ویژگی‌های از پیش استخراج‌شده، پردازش زبان طبیعی یادداشت‌های بالینی.	[24,25]
ترکیبی CNN-LSTM	استخراج ویژگی و مدل‌سازی توالی به صورت ترکیبی	از بهترین‌های هر دو بهره می‌برد: CNNها ویژگی‌های محلی استوار را استخراج می‌کنند و LSTMها روابط زمانی بین آن ویژگی‌ها را مدل‌سازی می‌نمایند. عملکرد در لبه‌ی فناوری (State-of-the-art).	پیچیدگی مدل و تعداد پارامترها افزایش می‌یابد؛ نیازمند تنظیم دقیق دو معماری متفاوت است.	زیاد	تشخیص فعالیت انسان (HAR) به صورت سرتاسری، تحلیل گام‌برداری، طبقه‌بندی مراحل خواب از روی EEG/EOG، تشخیص سقوط	[24,25]
CNN-LSTM با سازوکار توجه (Attention)	استخراج ویژگی و مدل‌سازی توالی به صورت متمرکز	با فراهم آوردن امکان تمرکز مدل بر روی مرتبط‌ترین گام‌های زمانی در یک توالی، عملکرد را بیشتر بهبود می‌بخشد و توضیح‌پذیری و استواری در برابر نویز را افزایش می‌دهد.	بالاترین پیچیدگی؛ یک لایه‌ی دیگر از فراپارامترها (hyperparameters) برای تنظیم اضافه می‌کند؛ می‌تواند از نظر محاسباتی پرهزینه باشد.	بسیار زیاد	تشخیص فعالیت‌های پیچیده با تفاوت‌های ظریف، تشخیص احساسات از روی سیگنال‌های فیزیولوژیک، پایش سلامت ورزشکاران.	[26,27]

7-4 یادگیری تقویتی برای بهینه‌سازی پویا

یادگیری تقویتی (RL) پارادایم متمایزی از یادگیری ماشین است که به طور استثنایی برای حل مسائل پیچیده‌ی تصمیم‌گیری متوالی تحت عدم قطعیت مناسب است[۳۱].

بهینه‌سازی شبکه و منابع: عامل با مشاهده‌ی وضعیت شبکه یک خط‌مشی بهینه‌ی تخصیص منابع را می‌آموزد [۳۴,۳۳,۳۲]. برای مثال، می‌توان از یک سیستم یادگیری تقویتی چندعامله برای طراحی یک پروتکل مسیریابی استوار استفاده کرد که یاد می‌گیرد از گره‌های مخربی که بسته‌های داده را حذف می‌کنند، دوری کند [۳۵].

پشتیبانی از تصمیم‌گیری بالینی و پزشکی شخصی‌سازی‌شده: این رویکرد پتانسیل عظیمی در کاربردهایی مانند بهینه‌سازی چرخه‌های شیمی‌درمانی، شخصی‌سازی دوز انسولین برای دیابتی‌ها، و مدیریت درمان سپسیس در واحدهای مراقبت‌های ویژه نشان داده است [۳۶,۳۱].

جدول 4 : کاربردهای یادگیری تقویتی در مراقبت‌های بهداشتی هوشمند

حوزه‌ی کاربرد	هدف یادگیری تقویتی	عامل (Agent)	محیط (Environment)	کنش‌ها (Actions)	سیگنال پاداش (Reward Signal)	نتایج/چالش‌های کلیدی	منابع
تخصیص منابع شبکه	به حداکثر رساندن طول عمر شبکه، توان عملیاتی یا کیفیت خدمات (QoS)؛ کمینه‌سازی تأخیر یا مصرف انرژی.	کنترل‌کننده‌ی شبکه، گره‌های حسگر مجزا.	شبکه‌ی حسگر بی‌سیم (لایه‌های فیزیکی/MAC).	تنظیم توان انتقال، انتخاب مسیر مسیریابی، تخصیص کانال/بازه‌ی زمانی.	مثبت برای تحویل موفق بسته، مصرف کم انرژی؛ منفی برای از دست رفتن بسته، تأخیر بالا.	بهبود کارایی و استواری شبکه **چالش:** طراحی عامل‌های یادگیری تقویتی سبک برای گره‌های با منابع محدود؛ هماهنگی چندعامله.	[17,32 – 35]
پشتیبانی از تصمیم‌گیری بالینی	به حداکثر رساندن بقا/بهبودی بیمار؛ کمینه‌سازی اثرات نامطلوب یا پیشرفت بیماری.	دستیار بالینی مبتنی بر هوش مصنوعی، سیستم درمان خودکار.	وضعیت فیزیولوژیک بیمار (که توسط داده‌ها نمایش داده می‌شود).	تجویز/تنظیم دارو، توصیه‌ی روش درمانی، زمان‌بندی یک فرایند (procedure)	مثبت برای بهبود پیامدهای سلامتی، پایداری؛ منفی برای وخامت حال، عوارض جانبی.	پتانسیل برای طرح‌های درمانی بسیار شخصی‌سازی‌شده و تطبیقی **چالش:** تعریف پاداش‌های مناسب، تضمین ایمنی، توضیح‌پذیری مدل، یادگیری از داده‌های آفلاین/محدود.	[31,36]

8-4 یادگیری فدرال برای همکاریِ حافظ حریم خصوصی

یادگیری فدرال (Federated Learning - FL) یک تکنیک یادگیری ماشین تحول‌آفرین است که برای پرداختن مستقیم به تضاد بنیادین میان نیاز به مجموعه داده‌های بزرگ و متنوع برای آموزش مدل‌های هوش مصنوعی استوار، و الزام مطلق برای حفاظت از حریم خصوصی حساس بیمار، طراحی شده است [۱۴],

داده‌های حوزه سلامت همچنین ذاتاً غیرمستقل و با توزیع غیر یکسان (non-IID) هستند [۱۶]. مهم‌تر از همه، اگرچه یادگیری فدرال از اشتراک‌گذاری داده خام جلوگیری می‌کند، اما ذاتاً در برابر حملات امنیتی و حریم خصوصی مصون نیست. [۱۵]. این فرایند تکرارشونده، امکان ایجاد مشارکتی یک مدل واحد و قدرتمند را فراهم می‌آورد بدون آنکه هیچ‌کدام از آن‌ها مجبور به اشتراک‌گذاری داده‌های حساس خود باشند [۱۶].

با این حال، یادگیری فدرال یک راه حل جادویی (silver bullet) نیست و مجموعه‌ی منحصربه‌فردی از چالش‌ها را با خود به همراه دارد. فرایند انتقال مکرر به‌روزرسانی‌های مدل می‌تواند سربار ارتباطی قابل توجهی ایجاد کند [۱۹].

مهاجمان پیشرفته می‌توانند به طور بالقوه از طریق حملات وارون‌سازی مدل، اطلاعات حساس را از به‌روزرسانی‌های مدل به اشتراک گذاشته‌شده استنباط کنند، یا می‌توانند از طریق حملات مسموم سازی داده، مدل جهانی را خراب کنند [۱۳].

جدول ۵ : یادگیری فدرال در مقابل یادگیری متمرکز در حوزه‌ی سلامت

معیار	رویکرد یادگیری متمرکز	رویکرد یادگیری فدرال	منابع
حریم خصوصی داده	ریسک بسیار بالا. نیازمند تجمیع تمام داده‌های خام بیمار در یک مکان مرکزی است که یک نقطه‌ی واحد برای نشت (breach) ایجاد می‌کند.	حفاظت بالا. داده‌های خام هرگز از کلاینت محلی (مانند سرور بیمارستان) خارج نمی‌شوند. تنها به‌روزرسانی‌های انتزاعی مدل به اشتراک گذاشته می‌شوند.	[13-16]
امنیت داده	آسیب‌پذیر در برابر نشت اطلاعات از مخزن داده‌ی مرکزی.	آسیب‌پذیر در برابر حملات نوین بر فرایند یادگیری، مانند مسموم‌سازی داده، وارون‌سازی مدل، و حملات استنتاجی بر روی گرادیان‌ها.	[13,15,19]
سربار ارتباطی	در حین بارگذاری اولیه‌ی داده بالا، اما در طول آموزش پایین است.	در سرتاسر فرایند آموزش به دلیل اشتراک‌گذاری تکرارشونده‌ی به‌روزرسانی‌های مدل بین کلاینت‌ها و سرور، بسیار بالا است.	[15,16,19]
هزینه‌ی محاسباتی	بر روی سرور مرکزی بالا؛ بر روی کلاینت‌ها پایین.	توزیع‌شده. بر روی کلاینت‌ها متوسط (برای آموزش محلی) و بر روی سرور متوسط (برای تجمیع).	[14-16]
عملکرد مدل	به طور بالقوه بالاتر، زیرا مدل به تمام داده‌ها به صورت یکجا دسترسی دارد. آموزش، پایدارتر و سرراست‌تر است.	می‌تواند با متمرکز قابل مقایسه باشد، اما عملکرد ممکن است به دلیل ناهمگونی آماری (داده‌های non-IID) میان کلاینت‌ها کاهش یابد.	[15,16,19]
مفروضات آماری	فرض می‌کند که تمام داده‌ها قابل تجمیع (pooled) و IID هستند.	به صراحت برای کار با داده‌های non-IID طراحی شده است، هرچند این موضوع همچنان یک چالش فنی قابل توجه است.	[15,19]
پیچیدگی سیستم	لجستیک آموزش مدل ساده‌تر است. پیچیدگی اصلی در زیرساخت امن داده و حاکمیت (governance) آن است.	بسیار پیچیده. نیازمند مدیریت آموزش توزیع‌شده، همگام‌سازی کلاینت‌ها و پروتکل‌های تجمیع امن است.	[13,15]

9-4 روندهای نوظهور و افق آینده‌ی مراقبت‌های بهداشتی هوشمند

در حالی که فناوری‌های اصلی توصیف‌شده در بخش قبل، وضعیت فعلی و پیشرفته‌ی این حوزه (state-of-the-art) را تعریف می‌کنند، حوزه‌ی مراقبت‌های بهداشتی هوشمند با سرعتی سرسام‌آور در حال تحول است. چندین روند قدرتمند و فراگیر در حال ظهور هستند که آماده‌اند تا چالش‌های کلیدی باقی‌مانده را برطرف کرده و نسل بعدی سیستم‌های پایش سلامت هوشمند را تعریف کنند. این روندها به صورت مجزا در حال توسعه نیستند؛ بلکه یک شبکه‌ی درهم‌تنیده‌ی عمیق را تشکیل می‌دهند که در آن، پیشرفت در یک حوزه، پیشرفت در حوزه‌های دیگر را ممکن و ضروری می‌سازد.

ظهور هوش مصنوعی توضیح‌پذیر (XAI) و ایجاد اعتماد بالینی: همزمان با یکپارچه‌تر شدن مدل‌های هوش مصنوعی در تصمیم‌گیری‌های بالینی پرخطر، ماهیت «جعبه سیاه» آن‌ها در حال تبدیل شدن به یک محدودیت به‌طور فزاینده غیرقابل دفاع است. یک پیش‌بینی که از نظر بالینی معتبر باشد، اگر پزشک نتواند منطق پشت آن را درک کرده یا به آن اعتماد کند، کاربرد عملی کمی خواهد داشت. این مسئله منجر به ظهور حوزه‌ی هوش مصنوعی توضیح‌پذیر (XAI) شده

است که به توسعه‌ی تکنیک‌هایی اختصاص دارد که تصمیمات مدل‌های پیچیده را برای کاربران انسانی شفاف و قابل تفسیر می‌کنند [۱۲].

هوش مصنوعی توضیح‌پذیر صرفاً یک ویژگی فنی مطلوب نیست؛ بلکه یک پیش‌نیاز بنیادین برای ایجاد اعتماد بالینیِ لازم برای پذیرش گسترده است. برای اینکه یک پزشک مسئولیت حقوقی یک درمانِ هدایت‌شده با هوش مصنوعی را بپذیرد، باید بتواند منطق آن را موشکافی کند. علاوه بر این، نهادهای نظارتی مانند FDA به طور فزاینده‌ای خواستار شفافیت در دستگاه‌های پزشکی مبتنی بر هوش مصنوعی برای تضمین ایمنی و اثربخشی هستند [۱۱]. روش‌های XAI می‌توانند با مشخص کردن اینکه کدام ویژگی‌های ورودی (مانند کدام بخش‌های خاص از یک موج ECG) در تصمیم یک مدل بیشترین تأثیر را داشته‌اند، این شفافیت را فراهم کرده و در نتیجه یک پیش‌بینی مبهم را به یک توصیه‌ی قابل اعتماد و قابل حسابرسی تبدیل کنند [۱۲].

یکپارچه‌سازی بلاک‌چین برای افزایش امنیت و یکپارچگی داده‌ها : در حالی که یادگیری فدرال ابزاری قدرتمند برای حفظ حریم خصوصی در اشتراک‌گذاری داده‌ها است، فناوری بلاک‌چین یک راه‌حل مکمل با تمرکز بر تضمین یکپارچگی داده، قابلیت حسابرسی و اعتماد غیرمتمرکز ارائه می‌دهد. بلاک‌چین یک دفتر کل توزیع‌شده و تغییرناپذیر است که می‌تواند تراکنش‌ها را به شیوه‌ای قابل تأیید و مقاوم در برابر دستکاری، به طور امن ثبت کند. در زمینه‌ی مراقبت‌های بهداشتی هوشمند، این امر چندین پیامد عمیق دارد. می‌توان از آن برای ایجاد یک ردپای حسابرسی (audit trail) شفاف و دائمی برای دسترسی به پرونده‌ی الکترونیک سلامت بیمار استفاده کرد که دقیقاً نشان می‌دهد چه کسی و در چه زمانی به داده‌ها دسترسی داشته است. در یک سیستم یادگیری فدرال، می‌توان از

بلاک‌چین برای ثبت تمام به‌روزرسانی‌های مدل از کلاینت‌های شرکت‌کننده استفاده کرد و یک سابقه‌ی غیرقابل تغییر ایجاد نمود که امنیت را افزایش داده و از دستکاری مخرب در فرایند تجمیع جلوگیری می‌کند [۱۳].

بلاک‌چین با غیرمتمرکز کردن اعتماد و ارائه‌ی اثبات رمزنگاری‌شده از یکپارچگی داده، می‌تواند به طور قابل توجهی امنیت و قابلیت اطمینان کل اکوسیستم مراقبت‌های بهداشتی را تقویت کند.

بلوغ پزشکی شخصی‌سازی‌شده و درمان‌های دیجیتال: هدف نهایی این سیستم‌های پایش پیشرفته، فراتر از ردیابی غیرفعال (passive tracking) و رسیدن به ارائه‌ی مداخلات بسیار شخصی‌سازی‌شده و پیش‌دستانه است. این روند در دو حوزه‌ی کلیدی در حال ظهور است. اول، پیشرفت پزشکی دقیقِ مبتنی بر هوش مصنوعی است که در آن طرح‌های درمانی دیگر بر اساس میانگین‌های جمعیتی نیستند، بلکه به صورت پویا متناسب با پروفایل منحصربه‌فرد یک فرد، با یکپارچه‌سازی اطلاعات ژنتیکی، عوامل سبک زندگی و داده‌های فیزیولوژیک آنی که از حسگرهای پوشیدنی ارسال می‌شوند، طراحی می‌گردند [۳۱]. برای مثال، یک سیستم هوش مصنوعی می‌تواند با مشاهده‌ی پاسخ منحصربه‌فرد یک بیمار خاص در طول زمان، دوز بهینه‌ی دارو را برای او بیاموزد. دوم، ظهور درمان‌های دیجیتال (DTx) است، که در آن یک اپلیکیشن نرم‌افزاری، که اغلب توسط هوش مصنوعی قدرت گرفته، خود به درمان تبدیل می‌شود. این می‌تواند شامل چت‌بات‌های مبتنی بر هوش مصنوعی باشد که درمان شناختی رفتاری برای سلامت روان ارائه می‌دهند، سیستم‌های واقعیت مجازی تطبیقی که تمرینات توانبخشی فیزیکی را هدایت می‌کنند، یا اپلیکیشن‌هایی که بر اساس پایش مداوم قند خون، راهنمایی‌های تغذیه‌ای شخصی‌سازی‌شده ارائه می‌دهند [۲۱].

نسل بعدی توانمندسازها: G۶، حسگری در مقیاس نانو و اینترنت اشیاء هوشمند (AIoT): تکامل آینده‌ی مراقبت‌های بهداشتی هوشمند توسط بلوغ فناوری‌های توانمندسازِ حتی قدرتمندتری که در حال حاضر در افق تحقیقاتی قرار دارند، به پیش رانده خواهد شد.

ارتباطات بی‌سیم G۶: چشم‌انداز G۶ فراتر از ارتباطات صرفاً سریع‌تر است. یک مفهوم کلیدی، یکپارچه‌سازی عمیق ارتباطات و حسگری است، که در آن خودِ سیگنال‌های بی‌سیم به عنوان یک روش حسگری استفاده می‌شوند. این امر می‌تواند پارادایم‌هایی مانند حضور از راه دور هولوگرافیک (holographic telepresence) برای مشاوره‌های از راه دور فراگیر و مکان‌یابی داخلی و ردیابی فعالیت فوق‌العاده دقیق را امکان‌پذیر سازد و مرز بین دنیای فیزیکی و دیجیتال در حوزه‌ی سلامت را بیش از پیش محو کند [۲۸].

فناوری‌های حسگری نوین: تحقیقات مستمر در علم مواد و نانوفناوری در حال هموار کردن راه برای نسل جدیدی از حسگرها است. این‌ها شامل حسگرهای مقیاس نانو که شاید روزی بتوانند در جریان خون به گردش درآیند تا نشانگرهای بیماری را در سطح مولکولی تشخیص دهند، و مواد انعطاف‌پذیر پیشرفته‌ای که منجر به دستگاه‌های پوشیدنی دقیق‌تر، کمتر تهاجمی و بهینه‌تر از نظر انرژی خواهند شد که قادر به پایش طیف وسیع‌تری از زیست‌نشانگرها هستند، می‌شود [۲۰].

اینترنت اشیاء هوشمند (AIoT): این روند، عمیق‌ترین سطح یکپارچگی بین هوش مصنوعی و اینترنت اشیاء را نشان می‌دهد. این امر نشان‌دهنده‌ی یک گذار از مدل فعلی که در آن دستگاه‌های IoT داده‌ها را جمع‌آوری کرده و سپس توسط هوش مصنوعی در ابر یا لبه تحلیل می‌شوند به آینده‌ای است که در آن خود دستگاه‌ها ذاتاً هوشمند هستند. در پارادایم AIoT، دستگاه‌ها در لبه‌ی نهایی (extreme edge) قادر به یادگیری خودران، تصمیم‌گیری مشارکتی و انطباق بدون اتکای مداوم به یک کنترل‌کننده‌ی مرکزی خواهند بود، که به سیستم‌های هوشمند حقیقتاً غیرمتمرکز و تاب‌آور منجر می‌شود [۳۷].

تحقق موفقیت‌آمیز این چشم‌انداز آینده، به حل هیچ‌کدام از این روندها به صورت مجزا وابسته نیست. در عوض، به پیشرفت همزمان سه ستون عمیقاً درهم‌تنیده بستگی دارد: اعتماد، امنیت و شخصی‌سازی. یک توصیه‌ی درمانی بسیار شخصی‌سازی‌شده و دقیق که توسط هوش مصنوعی ارائه شده، اگر پزشک به استدلال مبهم آن اعتماد نکند، هیچ ارزشی ندارد، و این امر بر نیاز به XAI تأکید می‌کند [۱۲]. به همین ترتیب، یک بیمار رضایت نخواهد داد که داده‌هایش برای قدرت بخشیدن به یک مدل شخصی‌سازی‌شده، هرچقدر هم که مؤثر باشد، استفاده شود، اگر باور نداشته باشد که سیستم امن است و از حریم خصوصی او محافظت می‌شود، که این خود اهمیت یادگیری فدرال و بلاک‌چین را برجسته می‌کند [۱۳، ۱۴]. در نهایت، یک سیستم می‌تواند کاملاً امن و قابل اعتماد باشد، اما اگر نتواند مزایای ملموس و شخصی‌سازی‌شده‌ای را برای پیامدهای سلامتی بیمار ارائه دهد، توسط نظام سلامت پذیرفته یا بازپرداخت نخواهد شد. این سه حوزه یک پیوند حیاتی (critical nexus) را تشکیل می‌دهند؛ آن‌ها مجموعه‌ای از الزامات به هم وابسته‌اند که باید به صورت یکپارچه توسعه یابند. یک پیشرفت در XAI مستقیماً پذیرش بالینی بیشترِ مدل‌های شخصی‌سازی‌شده‌تر را ممکن می‌سازد. یک پیشرفت در یادگیری فدرالِ سبک و امن، جمع‌آوری داده‌های متنوع مورد نیاز برای شخصی‌سازی را بدون نقض اعتماد بیمار، آسان‌تر می‌کند. نقشه‌ی راه آینده برای کل این حوزه، در نقطه‌ی تلاقی این دامنه‌ها قرار دارد.

۵ - نتیجه‌گیری: جمع‌بندی و توصیه‌های راهبردی

همگرایی هوش مصنوعی و شبکه‌های حسگر بی‌سیم بدون تردید در حال بازآرایی چشم‌انداز مراقبت‌های بهداشتی است و یک تغییر پارادایم از مدل واکنشی و بیماری‌محور به مدلی پیش‌دستانه و تندرستی‌محور را تسریع می‌کند. این گزارش تحلیلی جامع از این تحول ارائه داد و اکوسیستم پیچیده‌ی چالش‌ها، فناوری‌ها و روندهای نوظهور را که حوزه‌ی مراقبت‌های بهداشتی هوشمند و پایش بیمار را تعریف می‌کنند، کالبدشکافی کرد. این تحلیل، حوزه‌ای را آشکار می‌سازد که مشخصه‌ی آن مجموعه‌ای از تنش‌های بنیادین و روابط هم‌زیستی است که نوآوری را به پیش می‌رانند.

هسته‌ی چالش مهندسی را می‌توان در معضل سه‌گانه‌ی محدودیت منابع (Resource Constraint Trilemma) خلاصه کرد: یک توازن (trade-off)

دائمی و اجتناب‌ناپذیر میان نیاز به داده‌های غنی برای بـه حرکـت درآوردن هـوش مصنوعی قدرتمند، قابلیت کاربردی دستگاه‌های پوشیدنی کم‌تـوان و نامحسـوس، و کارایی شبکه‌های بی‌سیمی که آن‌ها را به هم متصل می‌کنند. این معضـل سـه‌گانه، یک رویکرد طراحی کل‌نگر را ایجاب می‌کند که هم‌زیستی پشته‌ی اینترنـت اشـیاء پزشکی (Symbiosis of the IoMT Stack) را به رسمیت بشناسد؛ جـایی کـه یک تصمیم در هر لایه‌ی واحد حسگری، ارتباطات یا هوشـمندی محـدودیت هـا و فرصت‌های آبشاری را در سراسر معماری ایجاد می‌کند. علاوه بـر ایـن، پیاده‌سـازی این سیستم‌ها در دنیای واقعـی تحـت حاکمیـت پیونـد سـه‌گانه‌ی اعتمـاد امنیـت شخصی سازی (Trust-Security-Personalization Nexus) قرار دارد؛ یـک شناخت از این واقعیت که دقت فنی به تنهایی کافی نیست. پذیرش بالینی معنـادار نیازمند پیشرفت همزمان و درهم‌تنیده در قابلیت اعتماد مدل‌های هوش مصـنوعی (از طریق XAI)، امنیت و حریم خصوصی داده‌های بیمار (از طریق یادگیری فـدرال و بلاک‌چـین)، و ارائـه‌ی مزایـای ملمـوس و شخصی‌سازی‌شـده بـرای پیامـدهای سلامتی بیمار است.

بر اساس این تحلیل جامع، توصیه‌های راهبردی زیر برای ذینفعـان کلیـدی جهـت هدایت تحقیقات، توسعه و سیاست‌گذاری‌های آینده پیشنهاد می‌شود:

برای پژوهشگران و مهندسان: هم‌طراحی و بهینگی را در اولویت قـرار دهیـد. عصـر طراحی اجزای سیستم به صورت مجزا (در سیلوها) به پایان رسیده است. تحقیقـات آینده باید یک روش‌شناسـی هم‌طراحـیِ کـل‌نگر را در پـیش بگیرنـد کـه بـه طـور همزمان به بهینه‌سازی در لایه‌های حسگری، ارتباطات و هوشمندی بپردازد. تمرکز اصلی باید بر توسعه‌ی راهکارهای سبک و بهینه از نظر منابع باشد. این شامل موارد زیر است:

هوش مصنوعی بهینه از نظر انرژی: پیشبرد تحقیقات در زمینه‌ی شبکه‌های عصبی کوانتیزه شده، مدل‌های هرس‌شده و دیگـر تکنیک‌هـای فشرده‌سـازی مـدل بـرای کاهش ردپای محاسباتی و انرژی هوش مصنوعی بر روی دستگاه‌های لبه.

یادگیری فدرال بهینه‌سازی‌شده: توسعه‌ی الگوریتم‌های نـوین بـرای کـاهش سـربار ارتباطی و بهبود پایداری آماری یادگیری فدرال در مواجهه بـا داده‌هـای non-IID حوزه‌ی سلامت.

امنیت سبک: نوآوری در پروتکل‌های رمزنگاری کارآمد و سـازوکارهای امنیتـی بـه کمک سخت‌افزار که حفاظتی استوار را بدون تحمیل بار اضافی بر گره‌هـای حسـگر با منابع محدود، فراهم آورند.

برای پزشکان بالینی و ارائه‌دهندگان خدمات بهداشتی: در همکـاری بین‌رشـته‌ای و برنامه‌های آزمایشی پیشگام باشید. یکپارچه‌سـازی موفقیـت‌آمیز ایـن فناوری‌هـا در جریان‌هـای کـاری بـالینی نیازمنـد همکـاری عمیـق میـان متخصصـان فنـی و حرفه‌ای‌های پزشکی است. پزشکان بالینی باید:

در توسعه‌ی هوش مصنوعی توضیح‌پذیر (XAI) مشارکت کننـد: بـه طـور فعـال در طراحی و اعتبارسنجی سیستم‌های XAI مشارکت نمایند تا اطمینان حاصـل شـود که توضیحات ارائه‌شده از نظر بالینی معنادار بوده و اعتماد ایجاد می‌کنند.

برنامه‌های آزمایشی (پایلوت) را رهبری کنند: پیشگام اجرای برنامه‌های آزمایشـی و کارآزمایی‌های بالینی با طراحی خوب برای ارزیابی دقیق اثربخشی، ایمنی و قابلیـت استفاده‌ی سیستم‌های پایش مبتنی بر هوش مصنوعی در دنیای واقعـی باشـند تـا مبنای شواهد (evidence base) مورد نیاز برای پذیرش گسترده‌تر و بازپرداخت هزینه‌ها را تولید کنند.

برای صنعت و فروشندگان فناوری: بـر قابلیـت همکـاری و استانداردسـازی تمرکـز کنید. از هم گسیختگی بازار فعلی اینترنت اشیاء پزشکی (IoMT) یـک مـانع قابـل توجه برای پیشرفت است. ذینفعان صنعتی باید:

در زمینه‌ی استانداردها همکاری کنند: از طریق سازمان‌های توسعه‌ی استاندارد بـه صورت مشارکتی برای ایجاد پروتکل‌های مشترک بـرای فرمت‌بنـدی داده (قابلیـت همکاری معنایی)، ارتباطـات و امنیـت تـلاش کننـد. یـک اکوسیسـتم بـاز و قابـل همکاری، نوآوری را پرورش داده و ارزشی بیشتر از سیستم‌های بسته‌ی اختصاصـی فراهم خواهد کرد.

برای کاربر طراحی کنند: بر روی اصول طراحی انسان محور سرمایه‌گذاری کنند تـا اطمینان حاصل شود که دستگاه‌ها و پلتفرم‌ها برای تمـام جمعیت‌هـای بیمـاران، از جمله سالمندان و افراد با سواد دیجیتال پایین، شهودی، قابل اعتماد و در دسـترس هستند.

برای سیاست‌گذاران و نهادهای نظـارتی: نـوآوری را همزمـان بـا تضـمین ایمنـی و برابری پرورش دهید. نهادهای نظارتی وظیفه‌ی حیاتی ایجاد چارچوبی را بـر عهـده دارند کـه نـوآوری را تشـویق کـرده و در عـین حـال از حقـوق بیمـار محافظـت و دسترسی عادلانه را تضمین کند. اقدامات کلیدی شامل موارد زیر است:

توسـعه‌ی مسـیرهای نظـارتی چابـک: مسـیرهای نظـارتی شـفاف، چابـک و قابـل پیش‌بینی برای دستگاه‌های پزشکی مبتنی بـر هـوش مصـنوعی ایجـاد کننـد کـه بتواننـد بـا سـرعت بـالای تغییـرات فناورانـه سـازگار شـوند. ایـن شـامل تـدوین دستورالعمل‌های واضـح بـرای اعتبارسـنجی مـدل‌های هـوش مصـنوعی یـادگیری ماشین و سیستم‌های XAI است.

ارائـه‌ی مشـوق بـرای فناوری‌هـای تقویت‌کننـده‌ی حـریم خصوصـی: پـذیرش فناوری‌هایی مانند یادگیری فدرال و بلاک چین را از طریق مشـوق‌های سیاسـتی و با شفاف‌سازی جایگاه آن‌ها در مقـررات حفاظـت از داده ماننـد HIPAA و GDPR ترویج دهند.

پـرداختن بـه شـکاف دیجیتـال: سیاسـت‌هایی را بـرای اطمینـان از اینکـه مزایـای مراقبت‌های بهداشتی هوشمند، نابرابری‌های موجود در سلامت را تشدید نمی‌کنند، اجرا کنند. این شامل طرح‌هایی بـرای بهبـود دسترسـی بـه اینترنـت پهـن بانـد در مناطق محروم و برنامه‌هایی برای ارتقای سواد سلامت دیجیتال است.

همگرایی هوش مصنوعی و شبکه‌های حسگر بی‌سیم دارای پتانسیل تحـول‌آفرینی برای ایجاد یک نظام سلامت است که هوشمندتر، کارآمدتر، شخصی‌سازی‌شـده‌تر و در نهایت، انسانی‌تر باشد. با این حـال، تحقـق ایـن پتانسـیل صـرفاً یـک مسـئله‌ی جبری فناورانه نیست. این امر نیازمند یک تلاش هماهنگ، مشارکتی و مسئولانه از

سوی تمام ذینفعان برای عبور از چالش‌های پیچیده‌ی فنی، اخلاقی و اجتماعی پیش رو است. مسیر پیش رو نیازمند تعهد به ساختن سیستم‌هایی است که نه تنها هوشمند، بلکه امن، قابل اعتماد و عادلانه برای همگان باشند.

۶ - مراجع

[1] S. R. Alikhani, M. M. ShirMohammadi, and S. Siahloei, "Designing a Network Information Security Monitoring System Based on Big Data Technology in a Government Organization in Iran," in *Proceedings of the 8th International Conference on Information Technology, Computer, and Telecommunications Engineering*, Tehran, Iran, 2024, vol. 8.

[2] S. Z. Majidian and M. Shirmohammadi, "Clustering and Routing in Wireless Sensor Networks Using Multi-Objective Cuckoo Search and Game Theory," *Electronic and Cyber Defense*, vol. 10, no. 3, pp. 11-20, Dec. 2022.

[3] J. Ko, C. Lu, M. B. Srivastava, J. A. Stankovic, A. Terzis, and M. Welsh, "Wireless sensor networks for healthcare," *Proceedings of the IEEE*, vol. 98, no. 11, pp. 1947–1960, Nov. 2010, doi:10.1109/JPROC.2010.2065210.

[4] M. M. Shirmohammadi, M. Chahardoli, **Wireless Sensor Networks**. Hamadan: Islamic Azad University, Hamadan Branch, 2012. ISBN: 978-964-543-103-5.

[5] M. M. Shirmohammadi, *AI Unboxed: Tools & Techniques for the Future*, 1st ed., vol. 1. [Online]. Available: https://www.researchgate.net/publication/389659219_AI_UNBOXED_TOOLS_TECHNIQUES_FOR_THE_FUTURE#fullTextFileContent, Mar. 2025, p. 144.

[6] S. M. R. Islam, D. Kwak, M. H. Kabir, M. Hossain, and K.-S. Kwak, "The internet of things for health care: A comprehensive survey," *IEEE Access*, vol. 3, pp. 678–708, 2015. doi: 10.1109/ACCESS.2015.2437951.

[7] A. Al-Fuqaha, M. Guizani, M. Mohammadi, M. Aledhari, and M. Ayyash, "Internet of things: A survey on enabling technologies, protocols, and applications," *IEEE Commun. Surv. Tutor.*, vol. 17, no.4, pp. 2347–2376, 4th Quart ,2015 doi:10.1109/COMST.2015.2444095.

[8] A. Mehra, D. Sharma, and A. Kumar, "Challenges and vulnerabilities of WSN-based IoT in the healthcare and medical industry," *in Integration of WSN and IoT for Smart Healthcare*, London, UK: CRC Press, 2021, pp. 225–241, doi: 10.1201/9781003107521-15.

[9] A. C. Djedouboum, A. A. Abba Ari, A. M. Gueroui, A. Mohamadou, and Z. Aliouat, "Big Data Collection in Large-Scale Wireless Sensor Networks," *Sensors*, vol. 18, no. 12, art. 4474, Dec. 2018, doi:10.3390/s18124474.

[10] S. Baumann, R. T. Stone, و E. Abdelall ."Introducing a Remote Patient Monitoring Usability Impact Model to Overcome Challenges," *Sensors*, vol. 24, no. 12, article 3977, 19 June۲۰۲۴ . doi: 10.3390/s24123977

[11] V. Kaymakçı, İ. Kasap, M. Sevindi, and V. Mevsim, "The role and future of artificial intelligence in primary care," *Journal of Turkish Family Physician*, vol. 15, no. 1, pp. 26–37, 2024, doi: 10.15511/tjtfp.24.00126.

[12] [1] B. Dhanalaxmi and P. V. V. S. Srinivas, "Efficient and intelligent garbage segregation using deep learning," *Int. Res. J. Adv. Eng. Hub (IRJAEH),* vol. 3, no. 1, pp. 1055-1059, 2025, doi:10.47392/IRJAEH.2025.0151.

[13] Y. Chen, Y. Sun, and X. Chen, "A secure and efficient federated learning scheme for smart healthcare systems," *Electronics*, vol. 13, no. 13, p. 2620, Jul. 2024. doi: 10.3390/electronics13132620.

[14] M. S. Ali et al., "Federated learning in healthcare: Model misconducts, security, challenges, applications, and future research directions—A systematic review," *arXiv,* May 2024, doi:10.48550/arXiv.2405.13832.

[15] A. Chaddad, Y. Wu, and C. Desrosiers, "Federated Learning for Healthcare Applications," *IEEE Internet of Things Journal*, vol. 11, no. 5, pp. 7339–7358, May 2024, doi: 10.1109/JIOT.2023.3325822.

[16] Q. Yang, Y. Liu, T. Chen, and Y. Tong, "Federated machine learning: Concept and applications," *ACM Trans. Intell. Syst. Technol.*, vol. 10, no. 2, pp. 1–19, January 2019. doi: 10.1145/3298981.

[17] S. Malhotra et al., "Deep reinforcement learning for dynamic resource allocation in wireless networks," *arXiv*, Feb. 2025, doi:10.48550/arXiv.2502.01129

[18] "Development of compact, low-power receiver for 5G smart devices," *IoT Insider*, Jun. 5, 2024. [Online]. Available: https:/www.iotinsider.com/industries/communications/development-of-compact-low-power-receiver-for-5g-smart-devices/. [Accessed: Jul. 12, 2025].

[19] S. Niknam, H. S. Dhillon, and J. H. Reed, "Federated learning for wireless communications: Motivation, opportunities and challenges," *IEEE Communications Magazine*, vol. 58, no. 6, pp. 46–51, Jun. 2020, doi: 10.1109/MCOM.001.1900461.

[20] S. Shajari, K. Kuruvinashetti, A. Komeili, and U. Sundararaj, "The Emergence of AI-Based Wearable Sensors for Digital Health Technology: A Review," *Sensors*, vol. 23, no. 23, art. 9498, Nov. 2023, doi:10.3390/s23239498.

[21] D. Yang, J. Wang, L. Huang, and T. Wang, "Design and implementation of a health monitoring system for the elderly in characteristic towns based on wireless sensor network," *Frontiers Public Health*, vol. 12, Oct. 2024, doi: 10.3389/fpubh.2024.1399648.

[22] J. Ding and Y. Wang, "WiFi CSI-Based Human Activity Recognition Using Deep Recurrent Neural Network," in *IEEE Access*, vol. 7, pp. 174257-174269, 2019, doi: 10.1109/ACCESS.2019.2956952

[23] M. D. Toruner, V. Shi, J. Sollee, W.-C. Hsu, G. Yu, Y.-W. Dai, C. Merlo, K. Suresh, Z. Jiao, X. Wang, S. Mao, and H. Bai, "Artificial intelligence-driven wireless sensing for health management," *Bioengineering*, vol. 12, no. 3, art. 244, Mar. 2025, doi: 10.3390/bioengineering12030244.

[24] Z. Baloch, F. K. Shaikh, M. A. Unar, M. Ikram, and W. Ahmed, "CNN-LSTM-based late sensor fusion for human activity recognition in big data networks," *Wirel*. Commun. Mob. Comput.,vol.2022,doi: 10.1155/2022/3729943

[25] J. Wu, J. Wang, A. Zhan, and C. Wu, "Fall detection with CNN-Casual LSTM network," *Information*, vol. 12, no. 10, art. 403, Sep. 2021, doi: 10.3390/info12100403.

[26] T. Y. Wang, J. Cui, and Y. Fan, "A wearable-based sports health monitoring system using CNN and LSTM with self-attentions," *PLoS ONE*, vol.18,no.10,art.e0292012,Oct.2023,doi:10.1371/journal.pone.0292012.

[27] M. A. Khatun, M. A. Yousuf, S. Ahmed, M. Z. Uddin, S. A. Alyami, S. Al-Ashhab, H. F. Akhdar, A. Khan, A. Azad, and M. A. Moni, "Deep CNN-LSTM with self-attention model for human activity recognition using wearable

sensor," *IEEE J. Transl. Eng. Health Med.*, vol. 10, art. no. 2700316, May2022, doi: 10.1109/JTEHM.2022.3177710.

[28] A. Kumar, R. Jain, M. Gupta, and S. M. N. Islam, Eds., *6G-Enabled IoT and AI for Smart Healthcare: Challenges, Impact, and Analysis*. Boca Raton, FL, USA: CRC Press, 2024, doi:10.1201/9781003321668.

[29] Kumar, H. "Wireless Sensor Networks in Healthcare System: A Systematic Review," *Wireless Pers Commun* 134, 1013–1034 ,2024, doi:10.1007/s11277-024-10954-2.

[30] M. A. Khatun, M. Bhattacharya, C. Eising, and L. L. Dhirani, "Time series anomaly detection with CNN for environmental sensors in Healthcare-IoT," in *Proceedings of the 2024 IEEE 12th International Conference on Healthcare Informatics (ICHI 2024)*, Orlando, FL, USA, Jun. 2024,pp.522–524, doi:10.1109/ICHI61247.2024.00075.

[31] H. Ali, "Reinforcement learning in healthcare: optimizing treatment strategies, dynamic resource allocation, and adaptive clinical decision-making," *International Journal of Computer Applications Technology and Research*, vol. 11, no. 3, pp. 88–104, Jan. 2022, doi: 10.7753/IJCATR1103.1007.

[32] J. J. Alcaraz, F. Losilla, A. Zanella, and M. Zorzi, "Model-based reinforcement learning with kernels for resource allocation in RAN slices," *IEEE Trans. Wireless Commun.*, vol. 22, no. 1, pp.486 - 501, Jan. 2023, doi:10.1109/TWC.2022.3195570.

[33] B. Zhao and X. Zhao, "Deep Reinforcement Learning Resource Allocation in Wireless Sensor Networks WithEnergy Harvesting and Relay," *IEEE Internet Things J.*, vol. 9, no. 3, pp. 2330–2345, Mar. 2022, doi: 10.1109/JIOT.2021.3094465.

[34] Z. Xu, Z. Zhong and B. Shi, "Deep Reinforcement Learning Based Resource Allocation Strategy in Cloud-Edge Computing System," *2022 International Joint Conference on Neural Networks (IJCNN)*, Padua, Italy, 2022, pp. 1-8, doi: 10.1109/IJCNN55064.2022.9892029.

[35] M. S. Hajar, H. Kalutarage and M. O. Al-Kadri, "RRP: A Reliable Reinforcement Learning Based Routing Protocol for Wireless Medical Sensor Networks," *2023 IEEE 20th Consumer Communications & Networking Conference (CCNC)*, Las Vegas, NV, USA, 2023, pp. 781-789, doi: 10.1109/CCNC51644.2023.10060225.

[36] H. A. Butt, A. Ahad, M. Wasim, F. Madeira, and M. K. Chamran, "5G and IoT for Intelligent Healthcare: AI and Machine Learning Approaches—A Review," in Smart Objects and Technologies for Social Good (GOODTECHS 2023), Lecture Notes of the Institute for Computer Sciences, Social Informatics and Telecommunications Engineering, vol. 556, Cham, Switzerland: Springer, 2024, pp. 1–17, doi: 10.1007/978-3-031-52524-7_8.

[37] H. Bhatia, S. N. Panda and D. Nagpal, "Internet of Things and its Applications in Healthcare-A Survey," *2020 8th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions) (ICRITO)*, Noida, India, 2020, pp. 305-310, doi: 10.1109/ICRITO48877.2020.9197816.

Intelligent Information Systems Journal
Islamic Azad University, Hamedan Branch

Intelligent Information
System Journal
Islamic Azad University
Vol. 4, No.8, 2025

Artificial Intelligence - based Smart Wireless Sensor Networks for Smart Healthcare and Patient Monitoring: Challenges, Technologies, and Emerging Trends

Mahdi Mirzaei[1], Mansur Esmaeilpour [۲]

1Undergraduate Student, Department of Computer Engineering, Ha. C., Islamic Azad University, Hamadan, Iran
mahdi.mirzaei2107@iau.ir
2 Assistant Professor, Department of Computer Engineering, Ha. C., Islamic Azad University, Hamadan, Iran
esmaeilpour@iau.ac.ir

Abstract

The convergence of Artificial Intelligence (AI) and Wireless Sensor Networks (WSNs) is fundamentally transforming the healthcare domain, driving a transition from reactive treatment models to a paradigm of proactive and personalized care. The significance of this trend lies in the ability of these technologies to address global pressures on healthcare systems, including aging populations, the prevalence of chronic diseases, and escalating costs. This paper aims to provide a comprehensive and multidisciplinary analysis of this field by examining its challenges, key technologies, and emerging trends.

The research methodology is based on a comprehensive analytical review of the current state-of-the-art, through a systematic dissection of challenges at three levels: device, learning, and system. By providing detailed comparative analyses of enabling technologies at each layer of the Internet of Medical Things (IoMT) architecture from wearable sensors and communication protocols like BLE and LoRaWAN to AI algorithms such as CNN-LSTM and Reinforcement Learning—this paper presents a comprehensive roadmap.

Key findings indicate that the primary engineering challenge in this domain is a trilemma among data richness, device longevity (battery life), and network efficiency. Furthermore, the successful implementation of these systems is contingent upon a triad of trust, security, and personalization, underscoring the necessity for simultaneous advancements in Explainable AI (XAI), privacy preserving solutions like Federated Learning, and the personalization of treatments.

The novelty of this paper lies in its presentation of a holistic and integrated analytical framework that, instead of examining technologies in isolation, focuses on the symbiotic relationships and mutual tensions between them. This approach provides actionable insights for researchers, clinicians, and policymakers to guide the development of the next generation of intelligent healthcare systems.

Keywords: Wireless Sensor Networks - WSN, Artificial intelligence, Smart Healthcare, Deep Learning, Wearable Sensors, Remote Patient Monitoring .