

Explainability  
Transparency

Medical Products

هوش مصنوعی در پژوهش

Diagnostics

Benchmarking

Artificial  
Intelligence

Therapy

Uncertainty  
Robustness

از آینده تا استقرار بالینی

Preventive Measure

هوش مصنوعی در خدمت سلامت

Data Quality  
Reference Data  
Comparability

تاریخ: 1404/8/29

ارائه‌دهنده: دکتر یاسین فدائی

دانشگاه: دانشگاه علوم پزشکی شهرکرد

# مقدمه: هوش مصنوعی در پزشکی

🤖 نقش هوش مصنوعی در تشخیص، درمان و تصمیم‌گیری‌های بالینی روز به روز پررنگ‌تر می‌شود.

📈 **مزایا:** افزایش دقت در تشخیص، سرعت بالا در پردازش داده‌ها، کشف الگوهای پنهان، و کمک به تصمیم‌گیری پزشکان.

⚠️ **ریسک‌ها:** احتمال سوگیری در داده‌ها، چالش‌های تفسیرپذیری، مسائل حریم خصوصی بیماران و امنیت اطلاعات.

👤 هدف نهایی: نه جایگزینی پزشک، بلکه تقویت توانایی‌های پزشکان برای مراقبت بهتر از بیماران.



# انواع مدل‌های هوش مصنوعی در پزشکی

## مدل‌های پیش‌بینی‌کننده:

مدل پیش‌بینی خطر سکته قلبی

مدل تشخیص زودهنگام سرطان پستان

مدل پیش‌بینی پاسخ به دارو

## مدل‌های پردازش تصویر:

تشخیص ضایعات در تصاویر MRI مغز

شناسایی شکستگی در تصاویر X-Ray

تحلیل اسلایدهای پاتولوژی دیجیتال

## مدل‌های زبانی:

استخراج اطلاعات از گزارش‌های پزشکی

تفسیر نتایج آزمایش‌ها به زبان ساده

مدل پیش‌بینی دیابت نوع ۲

مدل پیش‌بینی نیاز به بستری در ICU

مدل پیش‌بینی عوارض جراحی

بخش‌بندی ریه در تصاویر CT

تشخیص رتینوپاتی دیابتی از فوندوس چشم

شناسایی اختلالات قلبی از اکوکاردیوگرافی

خلاصه‌سازی خودکار پرونده پزشکی

# نقشه راه: مدل‌های پیش‌بینی‌کننده



نکته: اجرای صحیح همه مراحل، کلید موفقیت مدل‌های پیش‌بینی‌کننده در محیط بالینی است.

# گام 1: بیان مساله

در پژوهش‌های علوم پزشکی، باید مسأله‌ای انتخاب شود که هوش مصنوعی واقعاً بتواند به شکل معنی‌دار و منطقی در حل آن کمک کند.

وقتی می‌خواهید یک موضوع انتخاب کنید، این ۵ سؤال کلیدی را از خود بپرسید:

آیا داده‌های این مساله زیاد، پیچیده و متنوع هستند؟



آیا انسان‌ها در این کار خطا، ناهماهنگی یا محدودیت دارند؟



آیا زمان زیاد یا هزینه زیاد برای حل مساله صرف می‌شود؟



آیا الگوهای پنهانی وجود دارد که انسان نمی‌تواند ببیند؟



آیا محصول نهایی تحقیق می‌تواند در بالین قابل استفاده باشد؟



## گام 2: استخراج متغیرهای اولیه



**نظر متخصصین بالینی:** مشورت با پزشکان متخصص در حوزه مورد مطالعه برای شناسایی متغیرهای کلینیکی مهم و مؤثر در تشخیص و پیش‌بینی.

**مرور مقالات و گایدلاین‌ها:** بررسی سیستماتیک مطالعات مشابه قبلی و دستورالعمل‌های بالینی معتبر برای استخراج متغیرهای استاندارد.

**تعریف عملیاتی هر متغیر:** مشخص کردن نحوه دقیق اندازه‌گیری و ثبت هر متغیر برای اطمینان از یکنواختی داده‌ها.

**ایجاد فهرست اولیه از متغیرهای مستقل (پیش‌بینی‌کننده‌ها) و متغیر وابسته (خروجی) با جزئیات کافی.**

کیفیت مدل نهایی به شدت وابسته به انتخاب صحیح و جامع متغیرهای اولیه است.

## گام 3: اعتبارسنجی متغیرها

### معیارهای اعتبارسنجی متغیرها:

آیا همه متغیرها وجود دارند؟

آیا واقعاً مرتبط با خروجی است یا خیر؟

کیفیت کافی برای استفاده در مدل دارند یا نه؟

قابل اندازه‌گیری و قابل اتکا هستند؟

آیا سوگیری (Bias) وارد مدل نمی‌کنند؟

در صورت نیاز متغیرهای بومی اضافه گردد.

# گام 4: تعیین حجم نمونه (EPV)

## قانون طلایی حجم نمونه: EPV

EPV (Events Per Variable): برای هر متغیری که وارد مدل می‌کنیم، حداقل 10 تا 20 رویداد واقعی لازم است.

$$\text{حجم نمونه} = (\text{تعداد متغیرها} \times \text{EPV}) \div \text{شیوع}$$

این فرمول، تضمین می‌کند که مدل به اندازه کافی از نمونه‌های مثبت برای یادگیری الگوهای مرتبط استفاده کرده و از پدیده Overfitting جلوگیری می‌شود.

## انتخاب EPV مناسب

- مدل‌های خطی ساده: EPV = 10
- مدل‌های پیچیده (Random Forest, XGBoost): EPV = 15-20
- داده‌های نامتوازن یا با شیوع پایین: EPV = 20-25


## مثال عملی محاسبه

- 1 تعداد متغیرهای مدل: 15 متغیر
- 2 شیوع بیماری: 8٪ (0.08)
- 3 EPV مناسب: 20

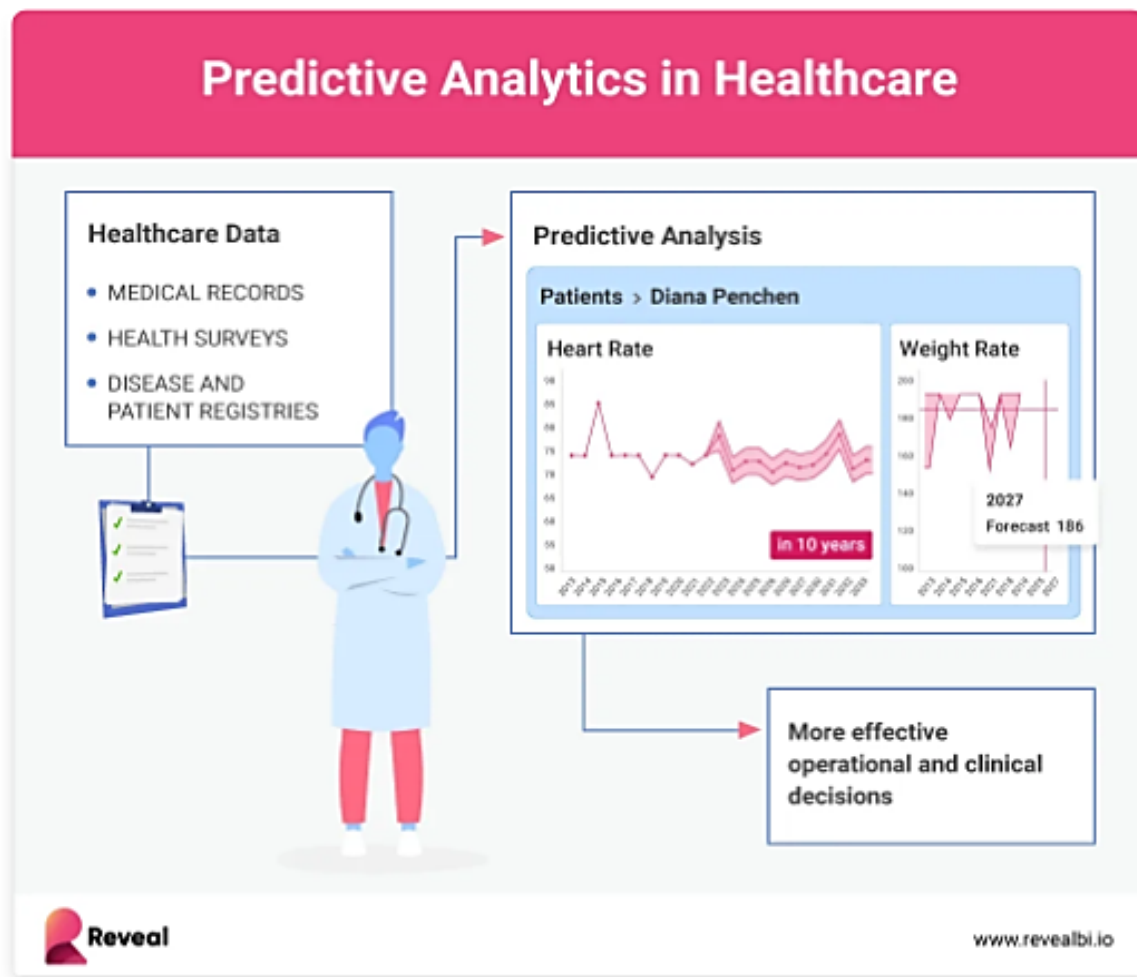
$$\text{محاسبه: } \text{حجم نمونه} = (15 \times 20) \div 0.08 = 3750$$

5 با احتساب داده‌های ناقص (20-30٪):

حجم نمونه نهایی  $\approx 5000-4000$



# گام 5: بررسی وضعیت داده‌ها



آیا داده‌های کافی با حجم مناسب و برجسته‌گذاری شده وجود دارد؟

مطالعه گذشته‌نگر (Retrospective): سریع و ارزان، اما با چالش‌های بسیار مانند داده‌های ناقص، سوگیری‌های متعدد، و خطاهای ثبت.

مطالعه آینده‌نگر (Prospective): زمان‌بر و پرهزینه، اما با کیفیت بالا، دقت بیشتر و کنترل کامل بر فرآیند جمع‌آوری.

انتخاب استراتژی جمع‌آوری داده باید با توجه به زمان، بودجه، و الزامات کیفیت پروژه انجام شود.

# گام 6: آماده‌سازی داده‌ها

## مراحل پیش‌پردازش داده

### Categorical (Encoding)

تبدیل متغیرهای غیر عددی به عددی با روش‌های One-Hot یا Label

### Outlier

شناسایی و مدیریت داده‌های پرت با روش‌های آماری

### Data Augmentation

افزایش حجم داده با ایجاد نمونه‌های مصنوعی برای آموزش بهتر

### Missing

مدیریت داده‌های گمشده با جایگذاری میانگین/میانه/مد یا پیش‌بینی

### Scaling & Normalization

جلوگیری از تسلط یک متغیر بر دیگر متغیرها با مقیاس‌بندی

### Balancing

متعادل‌سازی کلاس‌ها با SMOTE، Under/Over-Sampling

### نکته کلیدی:

داده خام همیشه پر از خطاست؛ مدل خوب از داده تمیز ساخته می‌شود.

## گام 7: انتخاب مدل

### نوع خروجی پیش‌بینی:

دوتایی-چندکلاسه: Logistic Regression، Random Forest، XGBoost، SVM، LightGBM، Multinomial Logistic Regression

### حجم داده:

کمتر 1000: Logistic Regression، SVM، Random Forest

متوسط بین 1000 تا 5000: Random Forest، XGBoost

بیشتر از 5000: XGBoost، LightGBM

خیلی زیاد: مدل‌های مبتنی بر شبکه‌های عصبی

### تفسیرپذیری:

Logistic Regression، Cox Model، Decision Tree (بیشترین قابلیت تفسیر برای کاربرد بالینی)

# گام 8: ارزیابی مدل

## ارزیابی آماری

**حساسیت (Sensitivity / Recall)**  
از بین بیماران واقعی، چند نفر را درست تشخیص داده؟

$$TP / (TP + FN)$$

**ویژگی (Specificity)**

از بین افراد سالم، چند نفر را درست سالم تشخیص داده؟

$$TN / (TN + FP)$$

**دقت کلی (Accuracy)**

چند درصد پیش‌بینی‌ها درست بوده‌اند؟

$$(TP + TN) / (TP + TN + FP + FN)$$

**دقت پیش‌بینی مثبت (PPV)**

از بین کسانی که مدل بیمار گفته، چند نفر واقعاً بیمار هستند؟

$$TP / (TP + FP)$$

## AUC-ROC

نموداری از Sensitivity در مقابل Specificity که توانایی تشخیص بیمار/سالم را نشان می‌دهد. هرچه به 1 نزدیک‌تر باشد، مدل قوی‌تر است.

پیش‌بینی شده

مثبت درست

TP

منفی نادرست

FN

مثبت نادرست

FP

منفی درست

TN

حقیقی

⚠ هشدار: مدل با دقت بالا اما تفسیرپذیری پایین، در محیط بالینی مورد اعتماد قرار نمی‌گیرد.

## گام 8: ارزیابی مدل

### 👤 ارزیابی بالینی

#### تفسیرپذیری (Interpretability)

در پزشکی هیچ مدلی بدون تفسیرپذیری وارد بالین نمی‌شود. پزشک باید بداند تصمیم مدل بر چه اساسی بوده است.

- SHAP Values: تعیین اهمیت هر متغیر در تصمیم‌گیری مدل
- LIME: توضیح محلی برای پیش‌بینی‌های مشخص
- Rule Extraction: استخراج قوانین تصمیم‌گیری از مدل‌های پیچیده


#### مقایسه با متخصصان انسانی

- آیا مدل حداقل به اندازه متخصصان عملکرد دارد؟
- آیا می‌تواند به پزشکان در تشخیص بهتر کمک کند؟
- آیا زمان تصمیم‌گیری را کاهش می‌دهد؟


## گام 9: اجرای پایلوت بالینی

### آزمون در محیط واقعی



استقرار محدود و کنترل شده در بخش کوچکی از بیمارستان 

سنجش عملکرد واقعی مدل و شناسایی مشکلات اجرایی 

ارزیابی اثر مدل روی کیفیت مراقبت از بیمار 


بررسی میزان پذیرش مدل توسط پزشکان و کادر درمان 

ارزیابی تأثیر بر جریان کار بالینی (Workflow) و فرایندهای موجود 

 نکته کلیدی:

"اگر مدل در کار روزمره پزشک جا نگیرد، حتی اگر بهترین دقت را داشته باشد، استفاده نخواهد شد."

بخش دوم



# مدل‌های پردازش تصویر

از دریافت DICOM تا گزارش قابل اتکا: فرآیند طراحی و پیاده‌سازی مدل‌های پردازش تصویر برای تشخیص و تحلیل تصاویر پزشکی



تشخیص رتینوپاتی  
دیابتی



شناسایی شکستگی در  
X-Ray



بخش‌بندی ریه در  
CT



تشخیص ضایعات در  
MRI

# گام‌های 1-3: تعریف مسئله، جمع‌آوری داده، برچسب‌گذاری



# گام 4: تعیین حجم نمونه تصویری

## اصول کلی:

- در مدل‌های پردازش تصویر، حجم نمونه بر اساس فرمول‌های کلاسیک تعیین نمی‌شود
- حجم نمونه تابع پیچیدگی مدل، تنوع داده، و هدف مطالعه است

## مدل‌های از پیش آموزش دیده:

- حداقل ۱۰۰۰۰-۱۵۰۰۰ تصویر برای هر کلاس لیبل (ResNet، EfficientNet، ViT)
- مناسب برای مواردی که داده محدود است اما نیاز به دقت بالا دارید

## آموزش از صفر:

- حداقل ۵۰۰۰ تصویر برای هر کلاس لیبل
- نیازمند منابع محاسباتی قوی‌تر و زمان آموزش طولانی‌تر

## موارد خاص:

- برای داده‌های ویدئویی: ۲ تا ۳ برابر حجم داده بیشتر نیاز است
- استفاده از Data Augmentation برای افزایش مصنوعی داده‌ها (Rotation، Flip، Zoom)
- پرهیز از Data Duplicates که باعث سوگیری در آموزش می‌شود

نکته: کیفیت داده‌ها همیشه مهم‌تر از کمیت صرف است. داده‌های متنوع با کیفیت بالا نتایج بهتری نسبت به داده‌های تکراری و کم‌کیفیت ارائه می‌دهند.

# گام 5: پیش‌پردازش تصاویر

استانداردسازی ابعاد تصویر: مدل‌های هوش مصنوعی اندازه ثابت می‌پذیرند (مثلاً  $224 \times 224$  یا  $512 \times 512$  پیکسل).

نرمال‌سازی شدت پیکسل‌ها: تبدیل مقادیر به بازه  $[0,1]$  برای آموزش سریع‌تر و پایدارتر مدل.


حذف نویز و بهبود کیفیت: فیلترهای مختلف برای تمرکز روی ساختارهای واقعی بافت، نه نویز تصویر.

برش ناحیه‌های غیرضروری: تمرکز بر منطقه مورد نظر (Region of Interest) برای بهبود دقت تشخیص.


تبدیل فرمت‌ها: تبدیل DICOM به JPG/PNG برای کاهش حجم داده و افزایش سرعت.

حذف اطلاعات حساس (De-identification): حفظ حریم خصوصی بیمار و رعایت اصول محرمانگی.

بدون پیش‌پردازش مناسب، حتی بهترین مدل‌های هوش مصنوعی نیز عملکرد ضعیفی خواهند داشت.



X-ray




(Magnetic Resonance Imaging)



CT scan



Ultrasound



PET scan  
(Positron Emission Tomography)

# گام 6: انتخاب و طراحی مدل

## مدل‌های طبقه‌بندی (Classification):

- ResNet: شبکه عمیق با اتصالات باقیمانده، کاهش مشکل گرادیان ناپدید شونده
- EfficientNet: توازن بین عمق، عرض و رزولوشن، کارایی بالا با پارامتر کمتر
- ConvNeXt: ترکیب مزایای CNN با ویژگی‌های Transformer

DenseNet: اتصالات متراکم بین لایه‌ها، استفاده بهینه از اطلاعات

Vision Transformer (ViT): بر پایه مکانیزم توجه، بدون استفاده از کانولوشن

## مدل‌های تشخیص ضایعه (Detection):

- YOLOv8/9: سریعترین مدل‌های تشخیص، مناسب برای کاربرد بلادرنگ
- RetinaNet: توازن بین سرعت و دقت، با تمرکز بر مشکل عدم توازن کلاس‌ها

Faster R-CNN: دقت بالا با معماری دو مرحله‌ای، استاندارد در تصاویر پزشکی

## مدل‌های تقسیم‌بندی (Segmentation):

- U-Net: معماری انکودر-دیکودر با اتصالات پرشی، استاندارد طلایی در پزشکی
- UNet3+: ترکیب اطلاعات چندمقیاسی با قابلیت یادگیری عمیق‌تر
- Swin-UNet: ترکیب ترنسفورمر پنجره‌ای با معماری U-Net

++U-Net: نسخه بهبودیافته U-Net با اتصالات پرشی متراکم‌تر

+DeepLabv3: ترکیب کانولوشن با نرخ اتساع و انکودر-دیکودر

# گام 7: ارزیابی مدل تصویری

• آماری:

تقسیم‌بندی بافت Segmentation

$$\frac{|A \cap B| \cdot 2}{|A| + |B|} = Dice$$

- A: سگمنت مدل
- B: سگمنت طلایی (پزشک/کارشناس)

تشخیص ضایعه Detection

$$\frac{|A \cap B|}{|A \cup B|} = IoU$$

- A: باکس مدل
- B: باکس واقعی (Ground Truth)
- $IoU \geq 0.5$  → قابل قبول
- $IoU \geq 0.75$  → خوب
- $IoU \geq 0.9$  → بسیار دقیق (برای پزشکی حساس)

دسته بندی Classification

- Sensitivity / Recall
- Specificity
- Accuracy
- AUC-ROC

• بالینی: مقایسه عملکرد مدل با عملکرد متخصصان انسانی.

# گام 8: پیلوت در محیط تصویربرداری

ادغام با PACS/RIS (سیستم‌های آرشیو تصاویر و اطلاعات رادیولوژی)

سنجش سرعت استنتاج و زمان پردازش در محیط واقعی

ارزیابی سیستم هشدار خطا و مدیریت موارد حاشیه‌ای

بررسی تجربه کاربری رادیولوژیست‌ها و کارکنان تصویربرداری

سنجش تأثیر بر Workflow و فرآیند کاری بخش تصویربرداری

بررسی تأثیر بر کیفیت و سرعت گزارش‌نویسی

## نکته مهم:

حتی بهترین مدل‌های پردازش تصویر، بدون ادغام مناسب با سیستم‌های موجود و پذیرش توسط کاربران بالینی، به مرحله استقرار واقعی نخواهند رسید.

# مدل‌های زبانی در پزشکی

## What is Natural Language Processing (NLP)?

### Complete Overview



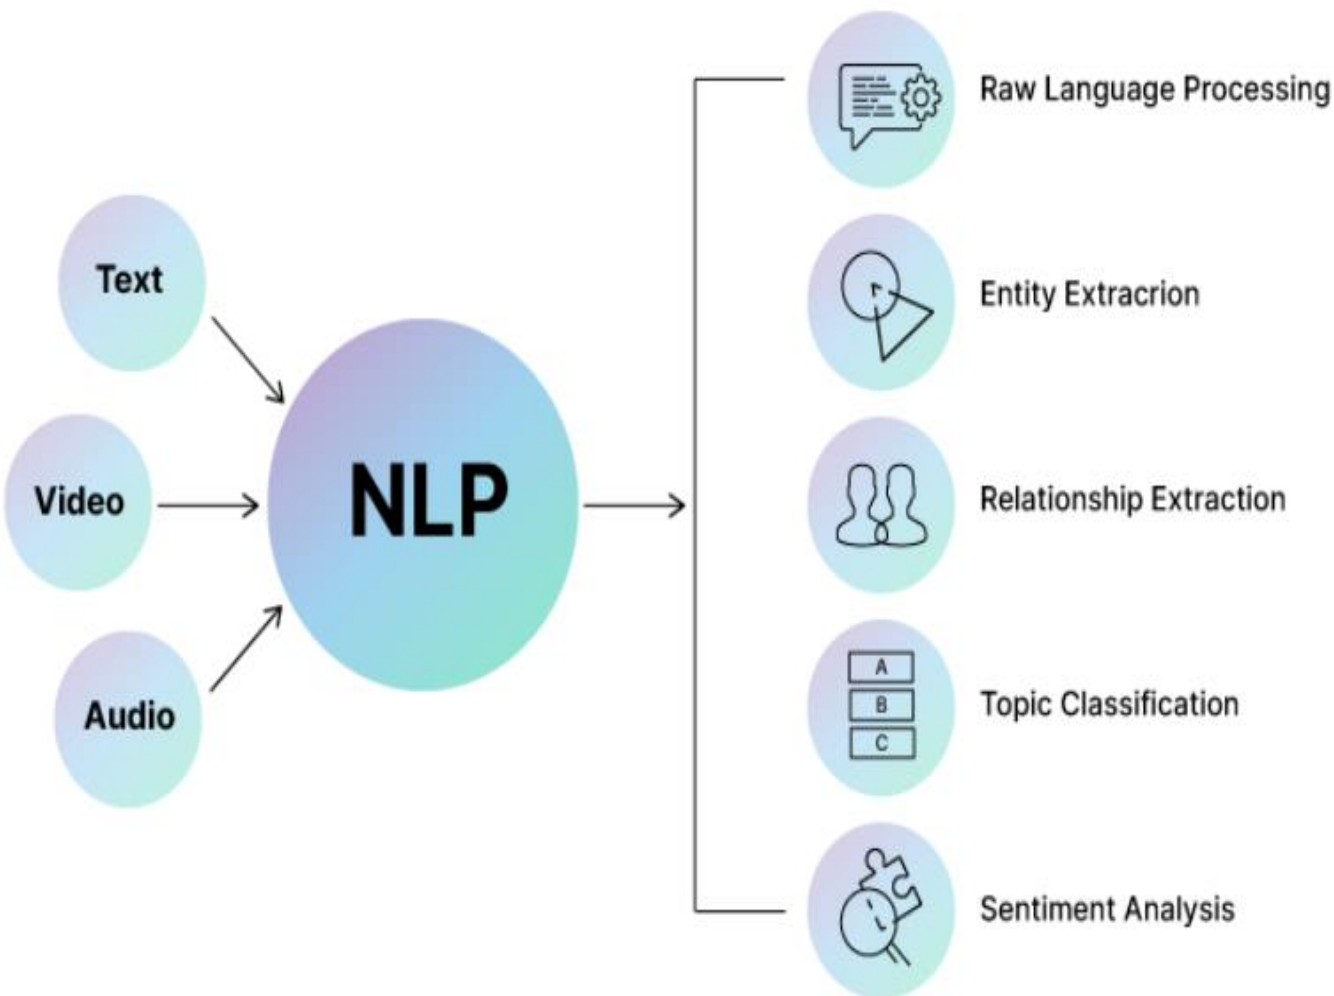
بخش سوم



Hi, I need help with my order status.



# گام 1: جمع‌آوری و آماده‌سازی داده متنی



**منابع داده:** پرونده‌های الکترونیک (EMR)، گزارش‌های بالینی، ثبت مکالمات پزشک-بیمار، مقالات علمی، گایدلاین‌ها

**پاک‌سازی:** حذف خطاهای تایپی، اصلاح ناسازگاری‌های املائی، استانداردسازی فرمت‌ها

**حذف اطلاعات شناسایی (De-identification):** حذف نام، شماره بیمه، آدرس و سایر اطلاعات حساس بیماران

**نرمال‌سازی اصطلاحات:** تبدیل به استانداردهای پزشکی مانند SNOMED CT (تشخیص‌ها)، ICD-10 (کدهای بیماری‌ها)، RadLex (اصطلاحات رادیولوژی)

**ساختاردهی:** تبدیل متون نامنظم به ساختارهای قابل تحلیل برای الگوریتم‌های پردازش زبان طبیعی

💡 کیفیت مدل‌های زبانی پزشکی به طور مستقیم وابسته به کیفیت و پاکیزگی داده‌های متنی اولیه است.

## گام 2: استراتژی ساخت مدل زبانی

### Instruction Tuning با سناریوهای بالینی

آموزش مدل با دستورالعمل‌ها و نمونه‌های واقعی پزشکی برای بهبود پاسخ‌دهی در موقعیت‌های بالینی مختلف.

### Fine-tuning روی LLM موجود

آموزش مجدد مدل زبانی بزرگ موجود با داده‌های پزشکی اختصاصی. رویکرد کم‌هزینه و رایج با نتایج قابل قبول برای اکثر کاربردها.

### Training از صفر

ساخت مدل زبانی اختصاصی از پایه. نیازمند داده و منابع محاسباتی عظیم، مناسب تنها برای سازمان‌های بسیار بزرگ.  
نکته: برای اکثر پروژه‌های بالینی، استفاده از راهکارهای قبلی توصیه می‌شود.

### RAG: بازیابی + تولید

اتصال مدل زبانی به پایگاه دانش پزشکی، گایدلاین‌ها و منابع به‌روز برای ارائه پاسخ‌های مستند و قابل استناد.

# مدل های بینایی-زبانی VLM

مدل های بینایی-زبانی (Vision-Language Models) توانایی درک و تحلیل همزمان تصاویر پزشکی و متون بالینی را دارند.


چرا برای علوم پزشکی مهم هستند؟

- توضیح پذیری: مدل می تواند توضیح دهد چرا ضایعه ای را تشخیص داده است.
- چندمنبعی بودن: می تواند همزمان تصویر + علائم + سن + آزمایش را تحلیل کند.
- خطاپایین تر از مدل های تک تصویری در موارد مبهم.
- قابلیت ساخت سیستم های کمک تشخیص واقعی.

# جمع‌بندی و توصیه‌های عملی

## Healthcare Data

- MEDICAL RECORDS
- HEALTH SURVEYS
- DISEASE AND PATIENT REGISTRIES




## Predictive Analysis

Patients > Diana Penchen

### Heart Rate



### Weight Rate



More effective  
operational and clinical  
decisions

از مساله بالینی واقعی شروع کنید، نه از تکنیک‌های هوش مصنوعی. مدل باید نیاز واقعی را برطرف کند.

کیفیت داده و تفسیرپذیری، کلید ورود به بالین است. بدون این دو، حتی دقیق‌ترین مدل‌ها اعتماد پزشکان را جلب نمی‌کنند.

اجرای پایلوت کنترل‌شده پیش از استقرار گسترده الزامی است تا اثرات جانبی ناخواسته شناسایی شوند.

تیم چندتخصصی متشکل از متخصصین بالینی، داده و هوش مصنوعی برای موفقیت ضروری است.

تکنولوژی به تنهایی کافی نیست، بلکه باید با دانش بالینی و اخلاق پزشکی همراه باشد.

# معرفی ابزار جستجو و یافتن شکاف تحقیقاتی

- Chatgpt.com
- Grok.com
- Gemini.com
- Scopus
- Pubmed
- Scispace
- Connected Papers
- Liner
- Notebooklm
- Researchrabit
- Consensus
- Answer This

# سپاسگزارم

از توجه شما به برنامه کاربردی هوش مصنوعی در پزشکی سپاسگزارم

دکتر یاسین فدائی - دانشگاه علوم پزشکی شهرکرد

Email: [Fadaei.yasin@gmail.com](mailto:Fadaei.yasin@gmail.com)