

욕창 예방을 위한 AI 기반 환자 움직임 모니터링 및 예측적 알림 웹 서비스 설계

윤성현, 이승수, 방진숙*

호서대학교 컴퓨터공학부

e-mail: 20240995@vision.hoseo.edu / 20241006@vision.hoseo.edu / bluegony@hoseo.edu

Design of an AI-Based Patient Movement Monitoring and Predictive Alert Web Service for Pressure Ulcer Prevention

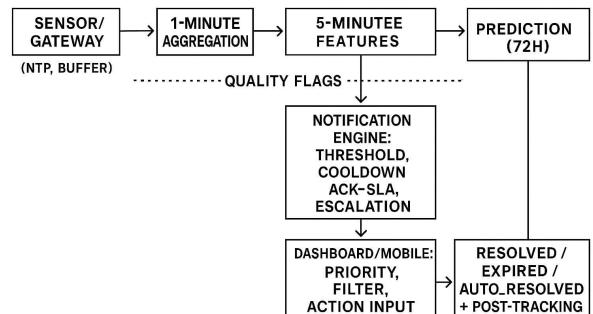
Sung-hyun Yoon, Seung-su Lee, Jin-suk Bang*
Dept. of Computer Engineering, Hoseo University

요약

본 논문은 환자 이동을 지속적으로 모니터링하고 예측 AI 알림을 발행하여 욕창을 예방하는 임상 웹 서비스 설계를 제시합니다. 이 아키텍처는 스트리밍 수집 계층, 1분 단위 및 5분 기능 윈도우, 72시간 위험을 추정하는 보정된 이진 위험 모델, 그리고 임상 조치(확인 SLA, 쿨다운, 에스컬레이션)를 구동하는 폐쇄 루프 워크플로를 통합합니다. PostgreSQL 스키마는 환자, 이동 로그, 예측 및 알림 상태 전환을 캡처하고, React-Vite(JavaScript + SWC) 프런트엔드와 FastAPI 백엔드는 저지연 상호작용을 제공하며, AWS EC2 기반 Docker는 재현할 수 있는 배포를 제공합니다. 이 시스템은 안정성과 확장성을 지원하기 위해 보안(RBAC, 전송/저장소 암호화, 감사 로그), 접근성(WCAG 2.2), 상호 운용성(HL7/FHIR)을 강화합니다. 알림 정책, UI 동작, 평가 지표(AUROC, AUPRC, ECE), 그리고 운영 목표(종단 간 지연 시간 ≤ 2분)를 명시합니다. 제안된 설계는 "예측 - 알림 - 임상 조치"를 욕창 예방을 위한 배포 가능한 웹 서비스로 변환한다.

키워드: pressure ulcer, patient movement, predictive alert, web service, MLOps, accessibility, FHIR

2.1 전체 아키텍처 및 파이프라인



[그림 1] 환자 움직임 모니터링 및 예측 알림 웹 서비스 아키텍처

데이터 수집과 동기화는 모든 장치를 NTP로 맞추고 UTC 타임스탬프를 저장하며, 게이트웨이는 24시간 로컬 베퍼와 맵 등 키(Idempotency Key)를 사용해 유실 데이터를 안전하게 재전송한다. 특징 추출은 1분 단위로 집계한 뒤 5분 이동 윈도우에서 총 움직임, 무반응 시간, 방향성 엔트로피, 주야 비율, 자리 비움 빈도와 지속 시간 등을 산출한다. 예측은 로지스틱 회귀 또는 의사결정나무로 72시

2. 본론

욕창은 고령·외상 환자에서 흔하며 통증, 감염, 재원 연장, 비용 증가를 유발한다[1]. 간헐적 수동 점검과 정적 위험 척도(예: Braden Scale)만으로는 선제적 개입의 타이밍을 놓치기 쉽다 [2]. 본 연구는 환자 움직임 데이터의 지속 모니터링, 72시간 욕창 위험 예측, 임계치·쿨다운·에스컬레이션**을 갖춘 알림 엔진, 그리고 대시보드 기반 임상 워크플로를 통합한 웹 서비스 설계를 제안한다.

우리는 (i) 수집→특징→예측→알림→조치의 폐 루프 (Closed-loop), (ii) SLA≤2분의 운영 목표, (iii) 접근성·보안·상호 운용성 기준을 충족하는 구현 원칙을 제시하고, (iv) 임상 현장에서의 재현 가능성을 보장하기 위한 평가 및 거버넌스 절차를 기술한다[6]–[8].

간 위험 확률을 계산하고 Platt Scaling 또는 Isotonic Regression 방법으로 이를 보정 한다[3]–[4]. 전체 E2E 자연은 데이터 수집부터 대시보드 반영까지 2분 이내로 유지 한다.

2.2 데이터 모델 & 예측 모델

Data Model & Prediction Model

| Entity/Module | Description |
|------------------|---|
| patients | Stores basic patient information and current risk status. Key attributes: patient_id (primary key), ward, braden_score (6–25 range), risk_prediction (0–1 range), > model_version. Always retained. |
| movement_logs | Logs patient movement events in UTC. Key attributes predicted_at, horizon_hours (default 72), probability, model_version, features_hash, calibrated. Index retained for at least one year. |
| prediction_runs | Manages state of alerts for pre-executions. Key attributes created_at, horizon_hours (default 72), status (NEW → ACKED → IN_PROGRESS → RESOLVED/EXPIRED/AUTO_RESOLVED), cooldown_key, calibrated. |
| alerts | Manages state of alert states irreversibly. Key attributes from_status, to_status, actor_id, note, event_time. Retained. |
| alert_events | Records changes of alert states irreversibly. Key attributes from_status, to_status, actor_id, note, event_time. |
| Prediction Model | Binary classifier estimates likelihood of pressure ulcer development within the next 72 hours. Feature engineering combines behavioral metrics—such as vital moments: age, sex, BMI, and Braden subscales. Key performance metrics: AUROC, AUPRC, ECE are assessed and managed. |

[그림 2] 욕창 72시간 위험 예측을 위한 데이터 모델 및 예측 모델

시스템은 여섯 개의 핵심 엔티티/모듈로 데이터를 정의하고 운용한다.

첫째, patients 엔티티는 환자 기본 정보와 현재 위험 상태를 보관한다. 주요 속성은 patient_id(기본 키), 병동(ward), Braden 점수(Braden_score, 6–23 범위 체크), 예측 위험도(risk_prediction, 0–1 범위 체크), 적용 모델 버전(model_version)이며, 참조 무결성과 범위 제약을 통해 데이터 일관성을 보장한다[2]. 이 테이블은 상시 보존한다.

둘째, movement_logs는 환자 움직임의 시계열 로그를 UTC 기준으로 저장한다. 핵심 속성은 이벤트 시작(timestamp), 이벤트 유형(event_type, 예: LEFT_TURN, RIGHT_TURN, SIT_UP, LEAVE_BED 등으로 구성된 폐쇄형 ENUM), 수집 원천(source), 품질 플래그(quality_flag), 순번(seq_no)이다. 대용량 시계열 처리를 위해 월별 파티셔닝을 적용하고, 조회 성능을 위해 (patient_id, timestamp) 복합 인덱스를 둔다. 또한 (patient_id, timestamp, source, seq_no)에 복합 유니크 제

약을 부여해 중복 기록을 방지한다. 원시 로그는 90일 보존 후 요약/집계 테이블로 이관하여 장기 보관한다.

셋째, prediction_runs는 예측 실행 이력과 감사를 위한 메타 데이터를 저장한다. 주요 속성은 예측 시각(predicted_at), 예측 지평(horizon_hours, 기본 72), 예측 확률(probability), 모델 버전(model_version), 입력 특징 해시(features_hash), 보정 여부(calibrated)이며, 최근 이력을 빠르게 조회할 수 있도록 (patient_id, predicted_at) 인덱스를 둔다. 재현성과 추적성을 위해 이 테이블을 최소 1년 이상 보존한다.

넷째, alerts는 예측 결과로 생성된 알림의 상태를 관리한다. 주요 속성은 생성 시각(created_at), 등급(grade: LOW/MEDIUM/HIGH), 상태(status: NEW → ACKED → IN_PROGRESS → RESOLVED/EXPIRED/AUTO_RESOLVED), 쿨다운 판별용 키(cooldown_key), 에스컬레이션 단계(escal_level)이다. 알림은 정의된 상태 전이 규칙과 쿨다운 정책을 염격히 따른다. 감사와 품질 관리를 위해 최소 1년 이상 보존한다.

다섯째, alert_events는 알림 상태 전이의 상세 이력을 불가역적으로 기록한다. 주요 속성은 이전 상태(from_status), 이후 상태(to_status), 행위자 식별자(actor_id), 비고(note), 이벤트 시각(event_time)이며, 포렌식과 컴플라이언스를 위해 2년 이상 보존한다.

여섯째, 예측 모델(이진 분류)은 향후 72시간 내 욕창 발생 위험 확률을 산출한다. 특징 공학은 총 움직임 양, 최대 무반응 시간, 주야 활동 비율, 방향성 엔트로피, 자리 비움 빈도·지속 등의 행동 지표와, 나이·성별·BMI·Braden 6개 하위 항목(감각인지, 습기, 활동, 기동력, 영양, 마찰/응전력) 같은 임상 지표를 결합한다. 검증은 시간 분할과 환자 ID 기반 그룹 분리를 병행하여 누수를 방지하고 일반화 성능을 점검한다. 확률 보정은 Platt 또는 Isotonic 방식을 사용하며, 운영 과정에서 분기 1회 이상 재보정 한다. 핵심 평가 지표로 AUROC, AUPRC, ECE 등을 산출·관리 한다[3]–[4].

2.3 알림 정책·임상 워크플로·접근성

알림 엔진은 등급화 규칙, 임계치/쿨다운/SLA/에스컬레이션, 라우팅과 UI 우선순위, EMR 연동과 사후 추적, 접근성 기준을 통합적으로 적용한다.

먼저 등급화 규칙은 다음과 같다. 예측 확률 p 가 상한 임계치 τ_{high} 이상이거나, 하한 임계치 τ_{low} 이상이면서 최근 무반응 시간이 2시간 이상이면 HIGH 등급으로 분류한다. $\tau_{low} \leq p < \tau_{high}$ 구간은 MEDIUM, $p < \tau_{low}$ 는 LOW로 분류한다. 이 설계는 조기 개입의 민감도를 확보하면서 알림 피로를 억제하는 균형을 노린다.

임계치 설정은 기본값으로 $\tau_{low}=0.25$, $\tau_{high}=0.60$ 을 제

시하고, 병동 인력/병상수에 맞춰 조정한다. 예컨대 30병상 기준으로 일일 총 알림 양을 12건 이하로 제한하는 운영 상한을 설정하여 임계치를 보정한다. 쿨다운 정책은 동일 환자·동일 등급 알림에 60분의 재발행 금지 기간을 적용해 중복 알림을 억제한다.

SLA는 응답 속도와 책임 소재를 명확히 정의한다. 신규 알림은 5분 내 확인(ACK) 해야 하며, 10분 내 IN_PROGRESS로 전환하여 조치를 개시한다. 조치 없이 4시간이 지나면 알림을 EXPIRED로 만료시킨다. 에스컬레이션 규칙은 미 ACK 5분 경과 시 책임 간호사로, 10분 경과 시 상처 전문간호사(WOCN) 또는 당직자로 승급하여 누락을 방지한다.

라우팅은 근무표와 병동 배치를 반영해 적절한 채널(푸시, 벨, 전화 등)로 전달 경로를 선택한다. 야간이나 소음 환경에서는 더 확실한 채널을 우선하여 전달 신뢰성을 높인다. UI 우선순위는 기본 정렬을 “HIGH → ACK 지연 순 → 무반응 시간순”으로 두고, 등급/병동 필터와 검색 기능을 제공한다. 간호사는 상세 화면에서 “조치 완료/메모/사진” 첨부를 입력해 알림을 RESOLVED로 종료할 수 있다. 이러한 상호작용은 알림을 행동으로 연결하도록 설계했다.

EMR 연동은 HL7/FHIR 표준을 사용해 오더 생성과 간호기록을 교환한다. 이를 통해 예측–알림–조치–기록까지 Closed-loop을 완결한다. 또한 사후 추적으로 알림 발생 후 24/48/72시간에 피부 상태와 재 알림 여부를 자동 수집하여 효과를 평가한다[7].

마지막으로 접근성 기준은 WCAG 2.2 AA를 준수한다. 색상만으로 의미를 전달하지 않도록 아이콘·페턴·텍스트를 중복 사용하고, 모바일 환경에서도 동일한 기능과 가독성을 제공한다. 이러한 기준은 임상 현장에서 다양한 사용자와 환경을 고려한 사용성을 보장한다[6].

2.4 평가·운영·거버넌스

우리는 모델과 알림 엔진의 품질을 정량적으로 관리하기 위해 AUROC, AUPRC, F1@k, Brier Score, ECE(Expected Calibration Error), Alert Rate(건/환자–일) 등 핵심 지표를 주기적으로 산출하고 장기 보관한다. 이러한 지표 산출은 단순 보고에 그치지 않고 임계치 조정과 운영 정책 개선의 근거로 활용하며, 대시보드에 시계열로 노출하여 추세를 상시 모니터링한다.

검증 단계에서는 시간 분할 방식과 환자 ID 기반 그룹 분리를 병행하여 데이터 누수를 차단하고 일반화 가능성을 점검한다. 우리는 내부 검증만으로 결론을 내리지 않고 최소 1개 이상의 외부 코호트에서 동일한 프로토콜로 재평가하여 기관·집단 간 편향을 확인한다. 예측 확률은 Platt 또는 Isotonic 방법으로 보정하고, 운영 환경의 분포 변화에 대응하기 위해 분기마다 보정 모델을 재학습하여 교정 오차(ECE)를 허용 범위로 유지한다[3]–[4].

운영 거버넌스 측면에서 우리는 모든 모델과 특징 세트를 레지스트리에 등록하여 버전, 학습 데이터 해시, 성능 지표를 추적한

다. 배포는 Shadow 단계에서 안전성을 확인한 뒤 Canary(10%)로, 점진적으로 노출하고, 문제가 없을 때 전면 배포로 확장한다. 배포 이후에는 입력 분포를 PSI(Population Stability Index)로 감시하고, 운영 AUPRC·Alert Rate 등 성능 지표를 함께 모니터링한다. 모니터링 값이 사전 정의한 기준을 이탈하면 자동 롤백을 즉시 수행하고, 원인 분석과 재학습 일정을 후속으로 실행한다[8].

보안과 컴플라이언스에서는 간호사 책임 간호사-WOCN·관리자로 구분되는 RBAC을 적용해 최소 권한 원칙을 준수한다. 데이터는 전송 구간에서 TLS로, 저장 구간에서 강한 암호화로 보호하며, 모든 접근·변경·배포·알림 처리 행위를 감사 로그로 남긴다. 우리는 감사 로그를 최소 2년 보존하고, 원시 움직임 로그는 90일 보관 후 요약·집계 형태로 장기화하며, 집계 데이터와 학습용 파생 데이터는 3년 보존 정책을 적용한다. 이러한 평가·운영·보안 체계는 예측–알림–임상 조치의 Closed-loop을 안정적으로 유지하면서도 재현성과 확장성을 보장한다.

3. 예상 결과

우리는 운영 목표를 지연과 응답 측면에서 명확히 설정하고 준수한다. 수집에서 특징 산출과 예측을 거쳐 대시보드에 반영되기 까지의 엔드투엔드 지연을 95퍼센타일 기준 2분 이내로 유지하고, 모든 알림이 95퍼센타일 기준 5분 이내에 ACK되도록 관리한다. 배포 승인 전에는 경보 품질 기준을 충족한다. 불균형 데이터 가정을 전제로 AUPRC 0.25 이상, ECE 0.05 이하의 보정 정확도를 확보하며, 30병상 기준 일일 알림량 12건 이하라는 운영 상한을 지킨다[3]–[4]. 현장 효과 측면에서 우리는 고위험 환자의 개입을 집중해 체위 변경과 피부관리를 신속히 수행하고, 쿨다운과 에스컬레이션 규칙으로 알림 피로를 통제한다. 이 Closed-loop 운영을 통해 욕창 발생률과 재원일 수 등 핵심 임상 품질 지표의 유의미한 개선을 유도한다.

4. 결론

본 연구는 환자 움직임 데이터와 예측형 알림을 단일 웹 서비스로 통합하여 “예측 – 알림 – 임상 조치”的 Closed-loop을 구현했다. 우리는 데이터 표준화, 알림 운영 규칙(임계치·쿨다운·SLA·에스컬레이션), 그리고 거버넌스(지표 관리·검증·보정·배포·모니터링)를 명시해 임상 수용성을 높였다. 구현 측면에서 우리는 React-Vite(JavaScript+SWC) 프런트엔드와 FastAPI 백엔드, PostgreSQL 데이터베이스를 사용해 빠른 인터랙션과 트랜잭션 무결성을 확보하고, Docker + AWS EC2로 환경 일관성과 롤링 배포를 유지했다. 또한 WCAG 2.2(접근성), RBAC·전송/저장 암호화·감사로그(보안), HL7/FHIR(상호운용성), MLOps (레지스트리·보정·드리프트 감시·자동 롤백)을 적용해 임상 현장에서 운영 가능하고 확장 가능한 서비스로 정착시켰다[6]–[8]. 동

시에 우리는 본 연구의 한계를 인정한다. 단일 기관과 특정 센서에 대한 의존, 라벨 정의(입원 시 기왕증(POA) 제외 및 Stage II+ 기준), 클래스 불균형, 그리고 알림 피로가 잠재 리스크로 남아 있다. 이에 우리는 다기관 외부 검증, 적응형 임계치 도입, 다양한 센서 융합, 자동 재학습과 운영 지표 기반의 지속 보정, 그리고 사용자 워크플로 중심의 피로 저감 설계를 향후 과제로 설정하고 단계적으로 추진한다. 이러한 방향을 통해 우리는 예측 기반 욕창 예방의 임상 효과와 일반화 가능성을 한층 강화할 것이다.

Acknowledgement

본 연구는 2025년 과학기술정보통신부 및 정보통신기획평가원의 SW중심대학사업 지원을 받아 수행되었음
(2025-0-00040)

참고문헌

- [1] National Pressure Ulcer Advisory Panel et al., “Prevention and Treatment of Pressure Ulcers/Injuries: Clinical Practice Guideline,” EPUAP/NPIAP/PPPIA, 2019.
- [2] Bergstrom, N., and B. Braden, “The Braden Scale for Predicting Pressure Sore Risk,” *Nursing Research*, Vol. 36, No. 4, pp. 205–210, 1987.
- [3] Platt, J., “Probabilistic Outputs for Support Vector Machines,” in *Advances in Large Margin Classifiers*, pp.-pp., 1999.
- [4] Zadrozny, B., and C. Elkan, “Transforming Classifier Scores into Accurate Multiclass Probability Estimates,” in *KDD*, pp.-pp., 2002.
- [5] Lundberg, S., and S.-I. Lee, “A Unified Approach to Interpreting Model Predictions,” in *NeurIPS*, pp.-pp., 2017.
- [6] W3C, “Web Content Accessibility Guidelines (WCAG) 2.2,” 2023, URL.
- [7] HL7, “FHIR Release (R5) Specification,” 2023, URL.
- [8] Sculley, D. et al., “Hidden Technical Debt in Machine Learning Systems,” in *NIPS*, pp.-pp., 2015.