

PRIMJENA NENADZIRANIH KLASIFIKACIJSKIH ALGORITAMA STROJNOG UČENJA ZA RANU DIJAGNOSTIKU RAYNAUDOVA SINDROMA U DJECE

Mario Šestan¹, Daniel Turudić¹, Martina Held¹, Nikola Škreb², Marko Barešić³, Nastasia Kifer¹, Marijan Frković¹, Jagoda Stipičić⁴, Danko Milošević⁵, Marija Jelušić¹

¹Medicinski fakultet Sveučilišta u Zagrebu, Klinika za pedijatriju, Klinički bolnički centar Zagreb, Zagreb, Hrvatska

²Medicinski fakultet Sveučilišta u Zagrebu, Klinika za bolesti srca i krvnih žila, Klinički bolnički centar Zagreb, Zagreb, Hrvatska

³Medicinski fakultet Sveučilišta u Zagrebu, Klinika za unutarnje bolesti, Klinički bolnički centar Zagreb, Zagreb, Hrvatska

⁴Medicinski fakultet Sveučilišta u Zagrebu, Klinika za neurologiju, Klinički bolnički centar Zagreb, Zagreb, Hrvatska

⁵Medicinski fakultet Sveučilišta u Zagrebu, Zagreb, Hrvatska

Uvod. Raynaudov fenomen (RF) često se susreće u pedijatrijskoj kliničkoj praksi. Trenutno je jedina općeprihvaćena slikovna metoda u dijagnostici RF-a kapilaroskopija. Međutim, druge dodatne slikovne metode, kao što je kompjutorizirana obojena teletermografija (CCTT), mogu poboljšati točnu klasifikaciju bolesnika s RF-om. Cilj ovog istraživanja bio je utvrditi dijagnostičku točnost dviju slikovnih metoda, kapilaroskopije i CCTT-a, u ranom otkrivanju RF-a.

Ispitanici i metode. Proveli smo retrospektivno presječno istraživanje koristeći nenadzirane klasifikacijske algoritme strojnog učenja za ranu dijagnostiku RF-a.

Rezultati. U istraživanje je uključeno 232 djece sa simptomima RF-a u razdoblju od 2010. do 2021. godine. Medijan (interkvartilni raspon) dobi bio je 15,21 (13,58 – 16,83) godina, s omjerom djevojčica i dječaka od 3,8:1. U 42,2% djece dijagnosticiran je primarni RF, u 21,6% sekundarni, dok u 36,2% nije bilo uočenog karakterističnog obrasca RF-a (simptomatski RF). Koristili smo tri JCHAIDStar algoritma, koji generiraju stabla odlučivanja, za klasifikaciju djece u podskupine s primarnim, sekundarnim i simptomatskim RF-om. Prvi algoritam koristi CCTT u prvom čvoru, a ostale varijable potrebne za klasifikaciju bolesnika jesu antinuklearna protutijela (ANA) (2. čvor) i protutijela na ekstraktibilne nuklearne antigene (ENA) (3. čvor) te beta-2 glikoproteinska protutijela (β 2-GPI). Preciznost JCHAIDStar algoritma uporabom LOOCV unakrsne validacije visoka je za sve grupe (primarni : sekundarni : simptomatski = 95,7% : 89,4% : 89,1%) s ROC područjima > 0,86. Drugi algoritam koristi kapilaroskopiju u prvom čvoru, a u ostalim β 2-GPI, ANA i ENA. Preciznost tog algoritma također je visoka (primarni : sekundarni : simptomatski = 81,7% : 95,8% : 85,0%) s ROC područjima > 0,82. Treći algoritam objedinjuje CCTT i kapilaroskopiju, uz ENA i IgG kao dodatne varijable uz preciznost 90,8% : 85,5% : 94,6%, i ROC područja > 0,9.

Zaključak. Preporučujemo korištenje i kapilaroskopije i CCTT-a u dijagnozi RF-a. Konstruirali smo jednostavne i isplative algoritme za klasifikaciju RF-a koji su primjenjivi u rutinskoj kliničkoj praksi.

Ključne riječi: Raynaudov sindrom, kompjutorizirana obojena teletermografija, kapilaroskopija, algoritmi strojnog učenja

Izjava o sukobu interesa: nema sukoba interesa