

VPLIV KOGNITIVNE OBREMENJENOSTI NA VEDENJSKE VZORCE POSAMEZNIKOV PRI OVERJANJU UPORABNIKOV

Andraž Krašovec¹, Veljko Pejović¹

¹Univerza v Ljubljani, Fakulteta za računalništvo in informatiko, Večna pot 113, 1000 Ljubljana
ak6688@student.uni-lj.si, veljko.pejovic@fri.uni-lj.si

Izvleček

Gesla in biometrični pristopi, na primer prstni odtisi, prevladujejo v svetu overjanja uporabnikov. Zaradi pomislekov glede varnosti, zasebnosti in priročnosti, znanost išče ustrezne nadomestke, vključujoč metode na podlagi vedenjskih vzorcev posameznikov. Kljub temu, da ti pristopi odpravijo večino obstoječih pomanjkljivosti, zaenkrat še niso dovolj natančni za splošno rabo. Glavni razlog za to je dejstvo, da uporabnikovo vedenje ni nespremenljivo. En izmed potencialnih vzrokov sprememb v obnašanju je spremenljiva kognitivna obremenjenost posameznika pri izvajanju različnih nalog. V tem delu na podlagi podatkov devetih prostovoljcev predstavimo raziskavo vpliva kognitivne obremenjenosti na vedenjske vzorce z analizo EEG in senzorskih podatkov. S pomočjo algoritma naključnega gozda razlikujemo med štirimi različnimi stopnjami kognitivne obremenjenosti. Dosežemo 89,79% in 76% natančnost na podlagi EEG in senzorskih podatkov, s čimer prikažemo povezavo med podatkovnima zbirkama.

Ključne besede: Kognitivna obremenjenost, overjanje uporabnikov, vedenjski vzorci.

EFFECT OF COGNITIVE LOAD ON BEHAVIOURAL PATTERNS OF INDIVIDUALS FOR USER AUTHENTICATION

Povzetek

Passwords and physical biometric approaches, such as fingerprints, are prevailing in the field of user authentication. Due to the security, privacy, and convenience concerns, alternative techniques arose, including methods based on behavioural patterns of users. Despite mitigating many existing issues, the underline performance of such authentication approaches is not up to par with more traditional methods. One factor that potentially lowers the performance of behaviour-based systems, is the level of cognitive load a person is under. This paper presents a preliminary study on the potential of EEG data for inference of cognitive load and the effect cognitive load has on behavioural patterns of users. We gather and process EEG and behavioural data and apply a Random Forest algorithm to it to predict four different levels of cognitive load. We achieve an 89.79% and 76.00% accuracy from EEG and behavioural patterns data respectively, displaying the connection between the two.

Keywords: Cognitive Load, User Authentication, Behavioural Patterns.

1 UVOD

Gesla so že desetletja najbolj pogost način overjanja uporabnikov [16]. Šele nedavno so se geslom pridružile tudi biometrične metode, na primer prstni odtisi in prepoznavna obraza. Pristopa predstavljata pomembna koraka v zgodovini overjanja uporabnikov, vendar ne zagotavljata sistema, ki bi bil varen in priročen za uporabnika. Overjanje na podlagi vedenjskih vzorcev, ki jih lahko opazujemo s pomočjo senzorjev v prostoru, se zanaša na uporabnikove nezavedne, vsakodnevne akcije in predstavlja zanimivo alternativo klasičnim pristopom.

Kljub priročnosti takšnega pristopa je potrebno premostiti še nekaj ovir preden lahko overjanje na podlagi vedenjskih vzorcev postavimo ob bok bolj uveljavljenim metodam. Na primer, nedavne raziskave prikazujejo

spremembe v vedenjskih vzorcih uporabnikov na različnih časovnih intervalih [13]. Ta problem najbolj vpliva na pogostost zavrnitve legitimnih uporabnikov kar negativno vpliva na uporabniško izkušnjo.

Eden izmed možnih vzrokov za spremembe vedenjskih vzorcev bi lahko bila trenutna stopnja kognitivne obremenitve posameznika. Kognitivna obremenjenost predstavlja obremenitev kognitivnega sistema posameznika pri opravljanju določene naloge [19]. V tem delu bomo preučili povezavo med kognitivno obremenitvijo in vedenjskimi vzorci uporabnika, ki jih lahko zaznamo s pomočjo senzorjev v okolju interneta stvari (IoT). Različne stopnje kognitivne obremenjenosti bomo prožili s prilagajanjem težavnosti eksperimentalnih nalog, ki jih prostovoljci opravljajo v prostoru, opremljenim s senzorji. Dodatno, v eksperimentu bomo nenehno spremljali možgansko aktivnost s pomočjo brezžične elektroencefalografske (EEG) čelade in s tem zgradili bogato podatkovno zbirko, ki jo bomo po koncu raziskave javno objavili.

Zato v tem delu, kolikor nam je znano, kot prvi;

- Opravimo preliminarno analizo vpliva različnih stopenj kognitivne obremenjenosti na vedenjske vzorce ljudi, zbrane s pomočjo senzorskih podatkov, v okviru overjanja uporabnikov.
- Sestavimo podatkovno zbirko, ki vključuje večmodalne senzorske IoT podatke in podatke o možganski aktivnosti na podlagi EEG. Končno podatkovno zbirko bomo javno objavili.

2 SORODNA DELA

Sistemi overitve uporabnikov na podlagi vedenjskih vzorcev predstavljajo alternativo bolj tradicionalnim metodam. Najbolj pogosto se takšni sistemi zanašajo na pametne naprave (telefoni, zapestnice) [20, 8, 17]. Manjšinski del področja, kamor se uvršča tudi naše delo, predstavljajo dela, ki uporabljajo senzorje interneta stvari, na primer v okolje postavljene radarji in inercialne merilne naprave [22, 7]. Pogost problem s katerim se ti sistemi srečujejo, je spremenljivost človeškega vedenja, kar negativno vpliva na natančnost in posledično uporabnost sistemov.

Eden izmed možnih razlogov spremenljivosti človeškega vedenja je prav tako spreminjajoča se stopnja kognitivne obremenjenosti posameznika. Kognitivna obremenjenost je definirana kot večdimenzionalni konstrukt, ki predstavlja obremenitev kognitivnega sistema posameznika pri izvajanju določene naloge [18]. Raziskave povezane s kognitivno obremenjenostjo domujejo v psihologiji [15], vendar lahko kognitivno obremenjenost analiziramo na mnogo področjih, kjer v študijah sodelujejo ljudje [5, 6] ali celo živali [4]. Barua et al. [1] povežejo kognitivno obremenjenost z zmožnostjo upravljanja avtomobila. Podobno Frösina et al. [10] raziščejo vpliv stopnje kognitivne obremenjenosti na vedenje osumljencev med zaslišanjem. Kolikor nam je znano, podobne analize vpliva kognitivne obremenjenosti na vedenjske vzorce za namen overjanja uporabnikov še ni opravil nihče.

EEG čelade so trenutno najbolj pogosto uporabljene naprave za prepoznavanje kognitivne obremenjenosti [9, 12]. Sodobni pristopi spajajo obdelavo podatkov s pomočjo hitre Fourierjeve transformacije z metodami strojnega učenja, najpogosteje z uporabo nevronske mreže [14, 2]. Poleg zgolj zaznavanja prisotnosti kognitivne obremenjenosti, so sodobni sistemi zmožni razlikovanja med različnimi stopnjami obremenitve ali celo zvezne napovedi.

Z zbranim znanjem opravimo prvo analizo vpliva kognitivne obremenjenosti na vedenje uporabnikov na področju sistemov overjanja. Zanašamo se na že opravljene analize na področju napovedovanja kognitivne obremenjenosti na podlagi podatkov z EEG naprav in pa tudi vedenjskih analiz, opravljenih na drugih raziskovalnih področjih.

3 ANALIZA KOGNITIVNE OBREMENJENOSTI

Ugotavljanje trenutne kognitivne obremenjenosti posameznika je zahtevna naloga. Trenutno najboljše metode se zanašajo na podatke, zbrane s pomočjo EEG naprav. V našem primeru sočasno zbiramo tudi vedenjske podatke, kar poveča kompleksnost našega sistema. V tem poglavju predstavimo postopek zbiranja in obdelave podatkov, katerih končni cilj je prepoznavanje različnih stopenj kognitivne obremenjenosti.

3.1 Eksperimentalne naloge

Vsak prostovoljec mora rešiti štiri naloge treh različnih težavnostnih stopenj v pisarniškem okolju. Prva naloga od uporabnika zahteva, da pretipka na zaslonu izpisano besedilo. Težavnostno stopnjo prilagajamo z izborom

Tabela 1: Ustvarjene značilke. EEG in ostali senzorski podatki so pri učenju uporabljeni ločeno.

Senzor	Ustvarjene značilke
EEG čelada	1 Hz moč signala (0-125 Hz)
Inercijske merilne naprave	1 Hz moč signala (0-100 Hz), povprečje, standardni odklon, stopnja prehoda povprečja
Senzorji sile	1 Hz moč signala (0-100 Hz), povprečje, standardni odklon, stopnja prehoda povprečja

jezika (materin jezik, angleščina, madžarščina). Naslednji nalogi spadata v družino Elementarnih kognitivnih nalog [11], namensko zasnovanih za vzbujanje različnih stopenj kognitivne obremenjenosti; a) *Skriti vzorci*, kjer mora uporabnik poiskati vrčtan lik v eni izmed treh ponujenih slik, kjer se težavnostna stopnja spreminja s kompleksnostjo ponujenih slik in b) *Zasledovanje*, kjer uporabnik sledi črtam s katerimi poveže števila na levi in desni strani slike, kjer se težavnostna stopnja spreminja s kompleksnostjo povezovalnih črt. Zadnja naloga od uporabnika zahteva, da se sprehodi do sosednjega zaslona, kjer prebere in si zapomni izpisano število. Zatem se sprehodi nazaj do primarnega računalnika, kamor po izteku časa to število vnese. Težavnostna stopnja je izražena z različnim številom števk v številu. V poskus je vključeno tudi stanje mirovanja, kjer uporabniki strmijo v prazen računalniški zaslon in poskušajo umiriti misli.

3.2 Zbiranje podatkov

Podatke možganske aktivnosti zbiramo s pomočjo 4-kanalne in brezžične EEG čelade Explore podjetja Mentalab¹. Čelado pred poskusi udeležencu namestimo na glavo in prilagodimo elektrode tako, da je njihova impedanca nižja od $100\text{ k}\Omega$, kar zadostuje priporočilu proizvajalca. Frekvenca vzorčenja je nastavljena na 250 Hz. Zaradi nestabilne povezave med napravo in strežnikom, se podatki zbirajo na napravi in prenesejo na strežnik po opravljenih meritvah.

Za zajem vedenjskih podatkov uporabimo naslednje senzorce;

- **Štiri inercijske merilne naprave.** Tri so pritrjene na vrh tipkovnice, medtem ko je četrta vgrajena v miško. Vsaka izmed naprav vsebuje triosni pospeškometer in žiroskop, kar nam omogoča tridimenzionalno zaznavanje pospeška in kotne hitrosti. Skupaj zajemamo 24 različnih signalov.
- **Štirje senzorji sile.** Pod miško in tipkovnico je postavljena plošča velikosti $70\text{cm} \times 40\text{cm}$, v vogalih katere so nameščeni senzorji sile, ki delujejo na podlagi spremembe upornosti s spreminjajočo se silo. Skupaj zajemamo 4 različne signale.

Pri analizi se zanašamo na vedenjske vzorce rokovanja uporabnika z računalnikom – inercijske merilne naprave zaznavajo ritem in hitrost pisanja na tipkovnico in način uporabe miške, medtem ko senzorji sile razpoznavajo držo pri delu z računalnikom. Analizo opravimo na podatkih devetih prostovoljcev (4 moški, 5 žensk), v povprečju starih 28,4 let.

3.3 Napoved kognitivne obremenjenosti

Poglaviti cilj našega dela je preveriti povezavo med kognitivno obremenjenostjo in vedenjskimi vzorci uporabnika. S pomočjo strojnega učenja poskušamo napovedati trenutno stopnjo kognitivne obremenjenosti na podlagi vedenjskih (senzorskih) podatkov, kjer nam podatki možganske aktivnosti služijo kot preverba težavnostnih stopenj eksperimentalnih nalog.


Obe vrsti podatkov razdelimo na sekundo dolge časovne intervale in na podlagi posameznih intervalov izračunamo značilke. Tako za senzorske kot EEG podatke uporabimo hitro Fourierjevo transformacijo s Hannovim oknom na podlagi katere pridobimo moč signala med 0 in 100 Hz (IoT) ali 0 in 125 Hz (EEG). Pri senzorskih podatkih dodatno izračunamo značilke v časovni domeni. Podatki pridobljeni s pomočjo EEG so zaradi narave uporabljenih elektrod občutljivi na šum. Analiza spektrograma pokaže izrazit vrh pri 50 Hz in podobnega, vendar manjšega pri 100 Hz, ki nastaneta zaradi prisotnosti naprav, priključenih v električno omrežje. Za odstranitev tega šuma uporabimo zarezni (ang. notch) filter. Celoten seznam značilk je predstavljen v Tabeli 1.

¹<https://www.mentalab.com/>

Ustvarjena podatkovna zbirka skupaj vsebuje 2141 primerov. Vsak primer je označen z razredom naše ciljne spremenljivke, ki jo predstavlja trenutna stopnja kognitivne obremenjenosti na podlagi težavosti naloge (odsotna, nizka, srednja, visoka). Zbirko razdelimo na posamezne uporabnike ter učno, validacijsko in testno množico (70%, 15%, 15%). V zadnjem koraku, na podlagi učne množice, ločeno naučimo naključna gozdova s senzorskimi in EEG podatki (oba napovedujeta stopnjo kognitivne obremenjenosti). Naključni gozd v obeh primerih vsebuje 1000 dreves, informacijski pribitek kot oceno kvalitete delitve drevesa in nima omejene največje globine drevesa. Izbrani parametri so določeni s pomočjo naključnega ter mrežnega iskanja in uporabo validacijske množice.

4 REZULTATI

V tem poglavju predstavimo analizo sposobnosti gručenja pridobljene podatkovne zbirke in rezultate, pridobljene na podlagi napovedovanja kognitivne obremenjenosti s pomočjo EEG čelade ter nato še s pomočjo senzorskih podatkov.



Slika 1: Primer dvodimenzionalne LDA projekcije EEG podatkov enega uporabnika. Različne barve (oblike) predstavljajo različne stopnje kognitivne obremenitve. Prikazuje se jasne gruče podatkov z enako stopnjo kognitivne obremenjenosti. Ena točka predstavlja sekundo meritev.

4.1 Analiza gručenja podatkov

Zmožnost gručenja podatkov v razrede različne kognitivne obremenjenosti nam poda prvi jasen znak ali lahko na podlagi pridobljenih EEG podatkov napovemo trenutno stopnjo kognitivne obremenjenosti. Podatke gručimo s pomočjo metode linearne diskriminantne analize (LDA). Primer gručenja podatkov za izbranega uporabnika je prikazan na Sliki 1. Opazimo lahko, da nastanejo jasne gruče primerov enake stopnje kognitivne obremenjenosti. Poleg tega lahko opazimo tudi jasno ločnico med primeri, ko uporabnik miruje ali opravlja nalogo. Podobni zaključki veljajo za vse uporabnike.

4.2 Napoved kognitivne obremenjenosti

Naslednji korak je napoved kognitivne obremenjenosti na podlagi podatkov zajetih z EEG čelade. Napovedujemo med štirimi različnimi stopnjami obremenitve. V tabeli napačnih klasifikacij, predstavljeni v Tabeli 2, opazimo močno diagonalno, saj je večina primerov razvrščenih v pravilni razred. Klasifikacijska točnost je 89,79%, kar pomeni da zasnovane eksperimentalne naloge dobro vzpodbudijo različne stopnje kognitivne obremenjenosti. Opazimo tudi, da mnogo primerov, ki so klasificirani napačno, pade v sosednje razrede, kar prikaže zveznost kognitivne obremenitve.

Tabela 2: Tabela napačnih klasifikacij napovedi stopnje kognitivne obremenjenosti za model naključnega gozda na podlagi EEG podatkov.

napovedani razred	visoka	0	0	4	89
	srednja	0	11	72	0
	nizka	0	54	9	0
	odsotna	73	0	0	9
		odsotna	nizka	srednja	visoka
		resnični razred			

4.3 Analiza vedenjskih vzorcev

Na podlagi potrditve različnih stopenj kognitivne obremenitve s podatki možganske aktivnosti, opravimo enako napoved tudi s pomočjo senzorskih podatkov. Dosežena klasifikacijska točnost je v tem primeru 76%. Vrednost je nižja kot pri EEG podatkih, vendar še vedno precej nad večinskim klasifikatorjem, ki doseže točnost 30,76%.

Možen vzrok za razliko v točnosti med EEG in senzorskimi podatki leži v naravi zbranih podatkov. Vedenjski vzorci se spreminjajo precej bolj nenadoma, saj v trenutku ko oseba preneha pisati, inercialne merilne naprave ne zaznavajo več ničesar. Na drugi strani se izkaže, da imajo podatki o možganski aktivnosti večjo vztrajnost, saj krajši postanki med mislimi ne sprožijo nenadne spremembe kognitivne obremenjenosti. Kljub temu lahko potrdimo prisotnost vpliva kognitivne obremenjenosti na vedenjske vzorce posameznika, saj lahko v več kot treh četrtinah primerov pravilno napovemo stopnjo kognitivne obremenjenosti na podlagi senzorskih (vedenjskih) podatkov.

5 ZAKLJUČEK

V tem delu smo raziskali vpliv kognitivne obremenjenosti na vedenjske vzorce uporabnika, zajete z zbirko senzorjev interneta stvari. S pomočjo algoritma naključnega gozda smo napovedovali štiri različne razrede kognitivne obremenjenosti in dosegli klasifikacijsko točnost 76%. Le-ta predstavlja znatno izboljšanje v primerjavi z večinskim klasifikatorjem (30,76%). S tem smo pokazali, da kognitivna obremenjenost vsaj delno vpliva na vedenjske vzorce uporabnikov, saj je moč razlikovati med težavnostnimi stopnjami nalog zgolj na podlagi vedenjskih podatkov, zajetih s senzorjev. Da zasnovane naloge uporabnika dejansko potisnejo v stanja različne kognitivne obremenjenosti, smo enake napovedi opravili še s pomočjo podatkov možganske aktivnosti z EEG čelade. Tukaj je klasifikacijska točnost dosegla 89,79%, kar potrjuje da so različne težavnostne stopnje nalog vzpodbudile različne stopnje kognitivne obremenjenosti pri uporabnikih.

Največja omejitev našega dela je velikost podatkovne zbirke. Zbirko nameravamo v prihodnosti razširiti z vključitvijo vsaj 100 prostovoljcev in dodatnimi senzorji, da bi lahko bolje razumeli vpliv kognitivne obremenjenosti na različne vidike obnašanja uporabnikov. Razširjeno podatkovno zbirko bomo uporabili za izgradnjo sistema overjanja uporabnikov, ki se je zmožen prilagajati različnim stopnjam kognitivne obremenjenosti. Kot posledica majhne podatkovne zbirke se v tem delu omejimo na algoritem naključnega gozda. Večja bera podatkov nam bo omogočila uporabo bolj naprednih tehnik, vključno z algoritmi globokega učenja. To nam bo pomagalo pri doseganju višje klasifikacijske točnosti in avtomatski ekstrakciji značilk.

Prav tako moramo biti pozorni na šum, ki lahko izhaja bodisi iz merilnih naprav bodisi iz osredotočenosti udeleženca poskusov. Zaradi šibkosti signala so za šum dovzetne predvsem EEG čelade, saj lahko šum preglasi signal, ki ga želimo zajeti. To sploh velja v laboratorijskem okolju z veliko različne elektronske opreme. Pri udeležencih največji izziv predstavlja motiviranost za opravljanje nalog. Neosredotočenost na nalogo v našem eksperimentu nam, namesto veljavnih podatkov z različnimi stopnjami kognitivne obremenitve, lahko prinese podatke, kjer so udeleženci zgolj nizko kognitivno obremenjeni.

Pri nadaljnjem delu nam podatek o stopnji kognitivne obremenjenosti na podlagi podatkov s čelade EEG predstavlja referenčno vrednost in potrditev, da različne težavnostne stopnje nalog res različno vplivajo na stopnjo kognitivne obremenjenosti posameznika. Na podlagi tega smo lahko tudi prepričani, da so bili tudi senzorski podatki in posledično vedenjski vzorci uporabnikov, podvrženi različnim stopnjam kognitivne obremenjenosti. S pomočjo tako označenih podatkov lahko razvijemo sistem overjanja uporabnikov, ki je sposoben identifikacije ne glede na trenutno stopnjo kognitivne obremenjenosti. To bomo storili v prihodnosti na podlagi razširjene podatkovne zbirke in s pomočjo tehnike prilagajanja domeni [3] ter nevronskih mrež z osnovno arhitekturo transformerjev [21].

LITERATURA

- [1] Shaibal Barua, Mobyen Uddin Ahmed, and Shahina Begum. Towards intelligent data analytics: A case study in driver cognitive load classification. *Brain Sciences*, 10(8):1–19, 2020.
- [2] Luis Cabañero, Ramón Hervás, Iván González, Jesús Fontecha, Tania Mondéjar, and José Bravo. Analysis of cognitive load using eeg when interacting with mobile devices. *Proceedings*, 31(1), 2019.
- [3] Youngjae Chang, Akhil Mathur, Anton Isopoussu, Junehwa Song, and Fahim Kawsar. A Systematic Study of Unsupervised Domain Adaptation for Robust Human-Activity Recognition. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 4(1):1–30, 2020.
- [4] Sarah J Davis, Steven J Schapiro, Susan P Lambeth, Lara A Wood, and Andrew Whiten. Behavioral conservatism is linked to complexity of behavior in chimpanzees (pan troglodytes): Implications for cognition and cumulative culture. *Journal of Comparative Psychology*, 133(1):20, 2019.
- [5] Cary Deck and Salar Jahedi. The effect of cognitive load on economic decision making: A survey and new experiments. *European Economic Review*, 78:97–119, 2015.
- [6] Cary Deck, Salar Jahedi, and Roman Sheremeta. The effects of different cognitive manipulations on decision making. *Economic Science Institute, Working Paper*, 2017.
- [7] Chao Feng, J I E Xiong, Liqiong Chang, Fuwei Wang, J U Wang, and Dingyi Fang. RF-Identity : Non-Intrusive Person Identification Based on Commodity RFID Devices. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 4(1):1–23, 8 2021.
- [8] Mario Frank, Ralf Biedert, Eugene Ma, Ivan Martinovic, and Dawn Song. Touchalytics: On the applicability of touchscreen input as a behavioral biometric for continuous authentication. *IEEE Transactions on Information Forensics and Security*, 8(1):136–148, 2013.
- [9] Nir Friedman, Tomer Fekete, Kobi Gal, and Oren Shriki. EEG-based prediction of cognitive load in intelligence tests. *Frontiers in Human Neuroscience*, 13(June), 2019.
- [10] Paul Frosina, Michael Logue, Andy Book, Tylor Huizinga, Steven Amos, and Scarlet. Stark. The effect of cognitive load on nonverbal behavior in the cognitive interview for suspects. *Personality and Individual Differences*, 130(February):51–58, 2018.
- [11] Eija Haapalainen, Seungjun Kim, Jodi F. Forlizzi, and Anind K. Dey. Psycho-physiological measures for assessing cognitive load. In *UbiComp'10 - Proceedings of the 2010 ACM Conference on Ubiquitous Computing*, pages 301–310, 2010.
- [12] Magdiel Jiménez-Guarneros and Pilar Gómez-Gil. Custom domain adaptation: A new method for cross-subject, eeg-based cognitive load recognition. *IEEE Signal Processing Letters*, 27:750–754, 2020.
- [13] Andraž Krašovec, Daniel Pellarini, Dimitrios Geneiatakis, Gianmarco Baldini, and Veljko Pejović. Not Quite Yourself Today: Behaviour-based Continuous Authentication in IoT Environments. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 4(4), 2020.
- [14] Júlio Medeiros, Ricardo Couceiro, Gonçalo Duarte, João Durães, João Castelhana, Catarina Duarte, Miguel Castelo-Branco, Henrique Madeira, Paulo de Carvalho, and César Teixeira. Can eeg be adopted as a neuroscience reference for assessing software programmers' cognitive load? *Sensors*, 21(7), 2021.
- [15] Laura Mieth, Raoul Bell, and Axel Buchner. Cognitive load does not affect the behavioral and cognitive foundations of social cooperation. *Frontiers in Psychology*, 7, 2016.
- [16] Robert Morris and Ken Thompson. Password Security: A Case History. *Communications of the ACM*, 22(11):594–597, 1979.
- [17] Talha Ongun, Alina Oprea, Cristina Nita-Rotaru, Mihai Christodorescu, and Negin Salajegheh. The house that knows you: User authentication based on iot data. In *Proceedings of the 2018 ACM SIGSAC Conference on Computer and Communications Security, CCS '18*, page 2255–2257, 2018.
- [18] Fred G. W. C. Paas, Jeroen J. G. van Merriënboer, and Jos J. Adam. Measurement of cognitive load in instructional research. *Perceptual and Motor Skills*, 79(1):419–430, 1994. PMID: 7808878.
- [19] Veljko Pejović, Tilen Matkovič, and Mojca Ciglarič. Wireless Ranging for Contactless Cognitive Load Inference in Ubiquitous Computing. *International Journal of Human-Computer Interaction*, 00(00):1–25, 2021.

- [20] Ioannis Stylios, Spyros Kokolakis, Olga Thanou, and Sotirios Chatzis. Behavioral biometrics & continuous user authentication on mobile devices: A survey. *Information Fusion*, 66(July 2020):76–99, 2021.
- [21] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N. Gomez, Łukasz Kaiser, and Illia Polosukhin. Attention is all you need. *Advances in Neural Information Processing Systems*, 2017-Decem(Nips):5999–6009, 2017.
- [22] Peijun Zhao, Chris Xiaoxuan Lu, Jianan Wang, Changhao Chen, Wei Wang, Niki Trigoni, and Andrew Markham. Human tracking and identification through a millimeter wave radar. *Ad Hoc Networks*, 116(December 2020):102475, 2021.

Andraž Krašovec je doktorski študent Fakultete za računalništvo in informatiko Univerze v Ljubljani. Trenutno je zaposlen kot raziskovalec na Skupnem raziskovalnem središču Evropske komisije. Njegovo delo se osredotoča na področje sistemov overjanja uporabnikov na podlagi vedenjskih vzorcev, zajetih s pomočjo tehnologij interneta stvari.

Veljko Pejović je doktoriral iz računalništva na Univerzi v Kaliforniji, Santa Barbara, ZDA. Po doktoratu je kot raziskovalec delal na Univerzi v Birminghamu, ZK. Od leta 2015 je zaposlen kot docent na Fakulteti za računalništvo in informatiko Univerze v Ljubljani (UL FRI), kjer vodi raziskave na temo mobilnega računanja, energetsko-učinkovitega računanja, računalniške varnosti, ter interakcije človek-računalnik. Nagrade, ki jih je dobil vključujejo Orange D4D challenge nagrado za modeliranje poteka epidemij s pomočjo podatkov iz mobilnih omrežij, ter Best paper nomination nagrado na konferenci ACM UbiComp. Več o njegovih raziskavah na <http://lrss.fri.uni-lj.si/Veljko/>